

UNIVERSIDADE DE LISBOA  
FACULDADE DE CIÊNCIAS  
DEPARTAMENTO DE ENGENHARIA GEOGRÁFICA, GEOFÍSICA E ENERGIA



## **Desenvolvimento de ferramenta de suporte a modelo de negócio inovador na área da eficiência energética em edifícios**

Filipe José Melo Neves da Silva

**Mestrado Integrado em Engenharia da Energia e do Ambiente**

Dissertação orientada por:  
Ricardo Rato (ISQ)  
Carla Silva (FCUL)

2017

## Agradecimentos

Em primeiro lugar gostava de agradecer aos orientadores desta dissertação, a professora Carla Silva e o engenheiro Ricardo Rato. Agradeço toda a sua ajuda na resolução de problemas e todas as suas sugestões e críticas que ajudaram a melhorar este trabalho. Agradeço também à engenheira Cláudia Mafra, que teve um papel fundamental no desenvolvimento deste trabalho.

Gostaria também de agradecer ao Dr. Nuno Moreira do Instituto Português do Mar e da Atmosfera e à Câmara Municipal de Mafra pela disponibilização de dados, que foram essenciais para a produção de resultados.

À equipa do *Sustainable Innovation Center* e ao Departamento de Energia do ISQ deixo grande um agradecimento pela vossa ajuda e simpatia que foram demonstrando ao longo do último ano.

Finalmente deixo um agradecimento todos os meus amigos e família, em especial à Sofia, à Filipa, ao Rafael, ao Márcio, ao Omar e ao Lopes, sem os quais eu não seria o mesmo e sem os quais este percurso teria sido muito complicado.

Dedico esta dissertação ao meu pai e à minha mãe, José e Aurélia, que sempre me apoiaram e me forneceram todas as ferramentas fundamentais para construir o meu futuro. Obrigado.

## Resumo

A eficiência energética é uma área que tem vindo a crescer e a atrair muito investimento. Com a expansão do mercado as soluções de eficiência energética em edifícios têm vindo a crescer e a permitir às Empresas de Serviços de Energia (ESE) implementar novos contratos de desempenho energético.

Apesar dos avanços na eficiência energética, hoje em dia ainda existem grandes lacunas entre o consumo previsto para um edifício durante a fase de projeto e o seu consumo real durante a utilização do edifício. Foi neste âmbito que surgiu o projeto MOEEBIUS (Modelling Optimization of Energy Efficiency in Buildings for Urban Sustainability). O projeto MOEEBIUS pretende reduzir essas lacunas, focando-se essencialmente na melhoria das atuais ferramentas de simulação de consumos, reduzindo o risco e potenciando desta forma a implementação de Contratos de Desempenho Energético (CDE).

Neste enquadramento, foi criada uma ferramenta (designada por MVtool) associada a um modelo de negócio inovador para as ESE. Esta ferramenta utiliza linguagem de programação *Python* para caracterização de *baselines* de consumo, sendo baseada numa regressão multilinear. A MVtool tem como objetivo apoiar as ESE, não só com a caracterização das *baselines* de consumo, mas também através da comparação de consumos reais com consumos previstos de modo a identificar poupanças energéticas geradas pelos CDE's.

A *baseline* de consumo é uma referência criada através da correlação entre o consumo e variáveis que o influenciam. Esta referência permite comparar consumos reais com consumos previstos para as condições da *baseline*. A MVtool tem algumas vantagens face a outras ferramentas semelhantes existentes no mercado, como por exemplo a exclusão automática de variáveis sem influência no consumo.

A MVtool foi validada e complementada com alguns métodos adicionais para ajudar o utilizador a tomar decisões. Depois de ser testada para vários edifícios concluiu-se que a ferramenta é capaz de produzir *baselines* suficientemente fortes para suportar decisões de negócio. Porém, verificou-se que alguns parâmetros têm muita influência no consumo e são essenciais para que esta funcione corretamente (por exemplo, a ocupação do edifício). Também se verificou que é fundamental efetuar ajustes pontuais à *baseline* para efetuar previsões adequadas, pelo que é necessário conseguir, no futuro, validar os métodos criados para identificar possíveis ajustes.

O edifício da Câmara Municipal de Mafra serviu de teste à ferramenta, assim como à comparação com outro tipo de modelo empírico: uma rede neuronal. A rede neuronal, baseada no método de regularização Bayesiana com uma camada de dez neurónios, permitiu obter resultados mais precisos que a MVtool, no entanto, sem a mesma capacidade de exclusão de variáveis cuja relação com o consumo é insuficiente para serem utilizadas e sem a mesma capacidade de identificação de possíveis ajustes à *baseline*.

Adicionalmente foram realizados os mesmos testes para outros quatro edifícios: duas escolas e dois edifícios de escritórios. Nestes edifícios observou-se que os resultados obtidos dependem significativamente do tipo de edifício, pois as escolas não dispõem de soluções de climatização e como tal as variáveis meteorológicas utilizadas na regressão e na rede neuronal não conseguem justificar as variações de consumo verificadas. Nos dois edifícios de escritórios foi possível criar um modelo de previsão com erro baixo, com qualquer uma das ferramentas aplicadas, uma vez que estes edifícios são fortemente climatizados e, desse modo, as variáveis meteorológicas já conseguem justificar as variações de consumo.

**Palavras-Chave:**

Previsão de consumos, Eficiência Energética, Regressão, Redes Neurais, Empresas de Serviços de Energia

## Abstract

Energy efficiency is an area that has been growing and attracting a lot of investment. With market expansion, the energy efficiency solutions in buildings have been growing and enabling energy service companies to implement new energy performance contracts.

Despite the advances in energy efficiency, there are still large gaps between the predicted consumption of a project during a design phase and its actual consumption during the use phase of the building. In an attempt to reduce that gap emerged the MOEEBIUS project (Modelling of Optimization of Energy Efficiency in Buildings for Urban Sustainability). The MOEEBIUS project will try to reduce these gaps by focusing mainly on improving the current energy simulation tools.

In this sequence, and associated with an innovative business model for energy services companies, a tool was made, MVtool, based on a multilinear regression. MVtool was built with Python programming language and its main goal is to characterize the consumption baselines. The objective of this tool is to support energy services companies' business, not only by characterizing baselines, but also to compare future energy consumptions with predicted energy consumptions so it is possible to identify energy savings generated by energy performance contracts.

The consumption baseline is a way to not integrate the influence of external factors into an energy prediction, allowing the tool user to create a model that depends on variables that influence consumption. MVtool also has some advantages towards other similar tools in the market, like the automatic exclusion of variable with low correlation with consumption or the fact that MVtool has no cost.

MVtool was validated and complemented with some additional methods to help decision making. After being tested with several buildings it was concluded that the tool is capable of producing strong enough baselines to support business decisions, but there are some variables that have a big influence in the buildings consumption and therefore the presence of this variables in the model is essential for this tool to work, such as building occupation. It was also verified that it is fundamental to make non-routine adjustments to the baseline for energy service companies business being successful, so it is necessary to validate the methods that identify possible adjustments, in the future.

Mafra Town Hall was the building in which the tool was tested and compared against the neural network. The neural network created used a Bayesian regularization method and had one layer with ten neurons. This network provided results with less error than MVtool's results, however, the neural network does not have the same capacity of exclusion of variables with low relation with consumption and it does not have the capacity of identifying possible baseline adjustments.

Additionally, the same tests were performed for another four buildings, two schools and two office buildings, in which it was observed that the quality of results depends heavily on the type of buildings being tested. In the schools, with low or non-existent climatization, the meteorological variables used in the regression and the neural network, are not able to justify the changes in the consumption. In the office buildings, it was possible to create a low error model with any of the tools, since office buildings are highly climatized.

### Keywords:

Energy Use Prediction, Energy Efficiency, Regression, Neural Networks, Energy Service Companies.

# Índice

Agradecimentos.....	ii
Resumo.....	iii
Abstract .....	v
Lista de Figuras .....	viii
Lista de Tabelas.....	x
Lista de Abreviaturas.....	xii
Capítulo 1 – Introdução.....	1
1.1 – Motivação e Enquadramento.....	1
1.2 – Objetivos.....	3
1.3 – Estrutura do trabalho .....	3
Capítulo 2 – Projeto MOEEBIUS .....	4
2.1 – Metodologia para definição de novos modelos de negócio ESE.....	4
2.2 – Novos modelos de negócio ESE.....	5
2.3 – Validação dos modelos de negócio ESE.....	5
Capítulo 3 – Estado da arte.....	6
3.1 – Legislação em eficiência energética .....	6
3.2 – Modelos de negócio ESE existentes .....	7
3.3 – Fases dos projetos ESE .....	7
3.3.1 – Desenvolvimento do projeto.....	7
3.3.2 – Fase de implementação.....	8
3.3.3 – Fase de aceitação .....	8
3.3.4 – Período de performance .....	8
3.3.5 – Fecho do projeto .....	8
3.4 – Medição e Verificação em CDEs .....	8
3.5 – Modelos de previsão de consumos energéticos .....	10
3.5.1 – Modelos avançados.....	10
3.5.2 – Modelos baseados em dados .....	11
Capítulo 4 – Metodologia.....	13
4.1 – Desenvolvimento do modelo de negócio.....	13
4.2 – Ferramenta de suporte.....	13
4.2.1 – Baselineing.....	14
4.2.2 – Descrição matemática .....	15
4.2.3 – Métodos Estatísticos .....	16
4.2.4 – Programa desenvolvido.....	20

4.2.5 – Validação .....	22
4.2.6 – Análise de sensibilidade .....	26
4.2.7 – Ferramenta baseada em redes neuronais.....	26
4.2.8 – Aplicação - Caso de estudo Câmara Municipal de Mafra.....	27
4.2.9 – Outros casos de aplicação .....	27
Capítulo 5 – Resultados e discussão.....	28
5.1 - Edifício da Câmara Municipal de Mafra .....	28
5.1.1 – Cenário base .....	29
5.1.2 – Introdução de novas variáveis.....	30
5.1.3 – Divisão da base de dados .....	34
5.1.4 – Técnicas adicionais .....	36
5.2 - Escolas em Mafra e em Loures.....	37
5.3 - Edifícios de escritórios em Lisboa .....	39
5.4 - Rede Neuronal – Comparações com a MVtool .....	41
5.4.1 – Edifício da Câmara Municipal de Mafra .....	41
5.4.2 – Escola de Mafra e Escola de Loures.....	43
5.4.3 – Edifícios de escritórios .....	44
Capítulo 6 – Conclusões.....	46
Referências .....	48
Anexo I – Business Model Canvas.....	50
Anexo II – Guia de utilização da MVtool .....	51

# Lista de Figuras

## Capítulo 1 - Introdução

Figura 1.1 - Principais utilizadores de energia final por sector, a nível mundial. ....1

Figura 1.2 – Diferença entre o consumo real e previsto em diferentes tipos de edifícios. Adaptado de MOEEBIUS. ....2

## Capítulo 3 - Estado da arte

Figura 3.1 - Esquema dos diferentes tipos de modelos de previsão de consumos. ....11

## Capítulo 4 - Metodologia

Figura 4.1 – Representação da distribuição *t-student*. ....18

Figura 4.2 – Exemplo da aplicação da linha delimitadora num gráfico de consumo. ....24

## Capítulo 5 - Resultados e discussão

Figura 5.1 – Gráfico matriz de consumos energéticos médios de uma semana representativa da estação de Inverno, para cada hora do dia e para cada dia da semana. Edifício da Câmara Municipal de Mafra. ....28

Figura 5.2 – Representação de uma semana de Janeiro, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.1. ....30

Figura 5.3 - Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.4. ....32

Figura 5.4 Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.5. ....33

Figura 5.5 – Exemplificação de previsões de consumo com e sem variáveis dependentes em situações de aplicação de medidas de conservação de energia. ....34

Figura 5.6 – Exemplificação de previsões de consumo com e sem variáveis dependentes em situações de aplicação de medidas de conservação de energia. ....36

Figura 5.7 - Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.13. ....38

Figura 5.8 - Gráfico matriz de consumos energéticos médios de uma semana representativa da estação de Inverno para cada hora do dia e para cada dia da semana. Edifício de escritórios A. ....39

Figura 5.9 - Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.13. ....40

Figura 5.10 - Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.13. ....41

Figura 5.11 – Comparação de resultados de previsão obtidos com o consumo real para uma semana de Inverno na CMM. ....42

Figura 5.12 – Comparação de resultados de previsão obtidos com o consumo real para uma semana de Verão na CMM. ....43

Figura 5.13 - Comparação de resultados de previsão obtidos com o consumo real para uma semana de Inverno na Escola de Loures. ....44

Figura 5.14 - Comparação de resultados de previsão obtidos com o consumo real para uma semana de Inverno no edifício A. ....45



## **Anexos**

Figura A.I.1 - Business Model Canvas para modelo de negócio “Serviços de Gestão de Energia baseado num CDE melhorado” . . . . .	49
Figura A.II.1 – Exemplo da folha “Baseline” do ficheiro input.xlsx. . . . .	53
Figura A.II.2 – Exemplo da folha “Savings” do ficheiro input.xlsx. . . . .	54
Figura A.II.3 – Exemplo de output da MVtool. . . . .	55

# Lista de Tabelas

## Capítulo 3 – Estado da arte

Tabela 3.1 – Comparação dos dois métodos de M&V descritos no IPMVP. ....	9
--	---

## Capítulo 4 - Metodologia

Tabela 4.1 – Comparação de resultados obtidos pela DexmaTech e pela MVtool para o mesmo grupo de dados. ....	23
--	----

## Capítulo 5 - Resultados e discussão

Tabela 5.1 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, sem tratamento de dados. ....	29
Tabela 5.2 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, após a substituição da temperatura pelos graus-hora de aquecimento e arrefecimento. ....	30
Tabela 5.3 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, após a introdução de todos os resultados potenciados ao cubo. ....	31
Tabela 5.4 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, após a introdução de uma variável binária de ocupação. ....	31
Tabela 5.5 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, após a introdução do consumo da hora anterior. ....	33
Tabela 5.6 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra para dias com ocupação. ....	34
Tabela 5.7 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra para dias sem ocupação. ....	34
Tabela 5.8 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, admitindo uma divisão do ano de <i>baselining</i> em cada <i>Change Point</i> encontrado. ....	35
Tabela 5.9 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, admitindo uma divisão do ano de <i>baselining</i> por trimestres. ....	35
Tabela 5.10 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, admitindo uma divisão do ano de <i>baselining</i> por mês. ....	35
Tabela 5.11 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, utilizando uma periodicidade diária de dados. ....	36
Tabela 5.12 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, utilizando dois anos para a caracterização da <i>baseline</i> de consumo. ....	37
Tabela 5.13 – Resultados da MVtool com tratamento de dados otimizado para a Escola de Mafra. ....	38
Tabela 5.14 - Resultados da MVtool com tratamento de dados otimizado para a Escola de Loures. ....	38
Tabela 5.15 - Resultados da MVtool com tratamento de dados otimizado para o edifício de escritórios A. ....	39
Tabela 5.16 - Resultados da MVtool com tratamento de dados otimizado para o edifício de escritórios B. ....	40
Tabela 5.17 – Comparação de resultados da MVtool e da rede neuronal para o edifício da Câmara Municipal de Mafra. ....	42
Tabela 5.18 - Comparação de resultados da MVtool e da rede neuronal para a Escola de Loures. ....	43

Tabela 5.19 - Comparação de resultados da MVtool e da rede neuronal para a Escola de Mafra. ....	44
Tabela 5.20 - Comparação de resultados da MVtool e da rede neuronal para o edifício A. ....	45
Tabela 5.21 - Comparação de resultados da MVtool e da rede neuronal para o edifício B. ....	45

## Lista de Abreviaturas

Acrónimo	Nome completo
ASHRAE	American Society of Heating, Refrigerating and Air-Conditioning Engineers
AVAC	Aquecimento, Ventilação e Ar Condicionado
BIM	<i>Building Information Model</i>
BMS	<i>Building Managment System</i>
CDE	Contrato de Desempenho Energético
CFE	Contrato de Fornecimento de Energia
CMM	Câmara Municipal de Mafra
CP	<i>Change Point</i> (Ponto de Mudança)
DR	<i>Demand Response</i>
EE	Eficiência Energética
ESE	Empresa de Serviços de Energia
FEMP	Federal Energy Management Program
ICP	Investor Confidence Project
IPCC	Intergovernmental Panel on Climate Change
IPMA	Instituto Português do Mar e da Atmosfera
IPMVP	International Performance Measurement and Verification Protocol
M&V	Medição e Verificação
MCE	Medida de Conservação de Energia
MOEEBIUS	Modelling Optimization of Energy Efficiency in Buildings for Urban Sustainability
nZEB	Nearly Zero Energy Building
RECS	Regulamento de Desempenho Energético dos Edifícios de Comércio e Serviços
REH	Regulamento de Desempenho Energético dos Edifícios de Habitação
SCE	Sistema de Certificação Energética
SGE	Serviços de Gestão de Energia
UMP	Uniform Methods Project
VRV	Volume Refrigerante Variável

## Capítulo 1 – Introdução

### 1.1 – Motivação e Enquadramento

A procura por energia elétrica tem vindo a aumentar e é expectável que até 2040 o consumo continue a crescer. As previsões indicam que em 2040 o consumo anual mundial será cerca de 30% superior ao consumo anual em 2014. Até esse ano, apenas na Europa Ocidental e Central se deverá verificar uma redução do consumo, no entanto só será possível reduzir o consumo à escala global quando grandes consumidores como a América do Norte e o Sudeste Asiático começarem também a reduzir os seus consumos [1][2].

Para evitar os cenários de aquecimento global, previstos pelo *Intergovernmental Panel on Climate Change* (IPCC), é necessário reduzir as emissões de gases de efeito estufa [3]. Para tal, será necessário encontrar formas alternativas de gerar a energia de que necessitamos ou reduzir as nossas necessidades energéticas. A Eficiência Energética (EE) é uma área que pretende reduzir o consumo de energia sem comprometer qualquer atividade, o conforto ou a saúde do Homem.

A energia final é essencialmente utilizada por cinco setores (Figura 1.1), sendo que dois destes (residencial e serviços) estão intrinsecamente relacionados com os edifícios [4]. A melhoria da eficiência energética nos edifícios é uma forma de limitar o consumo de energia e, assim, mitigar os efeitos ambientais negativos deste consumo.




Figura.1.1 - Principais utilizadores de energia final por sector, a nível mundial. [4]

O MOEEBIUS (*Modelling Optimization of Energy Efficiency in Buildings for Urban Sustainability*) é um projeto de investigação europeu, financiado pelo programa Horizonte 2020, na área da eficiência energética e tem como principal objetivo a redução da discrepância entre a previsão do consumo de energia em edifícios e o seu valor de consumo real.

A grande vantagem introduzida pelo MOEEBIUS assenta no facto de este criar ferramentas que possibilitam às Empresas de Serviços de Energia (ESE) efetuar previsões mais precisas do consumo

energético real de um edifício após a implementação de Medidas de Conservação de Energia (MCE), o que se traduz no aumento da confiança dos consumidores finais e das instituições financeiras nos modelos de negócios ESE.

Este projeto europeu é motivado pelas lacunas de desempenho observadas atualmente nos edifícios (Figura 1.). As lacunas de performance são as diferenças verificadas entre o consumo que foi previsto inicialmente e o consumo real. O consumo real chega a ser 2.5 vezes superior ao consumo previsto para alguns tipos de edifícios, o que demonstra o potencial existente para a melhoria da eficiência energética [5].




Figura 1.2 – Diferença entre o consumo real e previsto em diferentes tipos de edifícios. Adaptado de MOEEBIUS

Nos edifícios de serviços existe um potencial significativo de aumento da eficiência energética, o que se pode traduzir num respetivo potencial de poupanças, fazendo deste um mercado financeiramente atrativo. Segundo a *International Energy Agency* (IEA), em 2015, o mercado da eficiência energética teve um investimento de 221 milhares de milhões de US dólares, um investimento que ultrapassou o investimento em potência elétrica instalada em cerca de 70%. Deste investimento, é referido que o sector mais forte foi o sector dos edifícios, arrecadando quase um quarto do valor total. A consciencialização dos problemas ambientais também fez com que a procura por edifícios mais eficientes aumentasse, o que contribuiu para estes grandes investimentos [6].

As Empresas de Serviços Energéticos (ESE's) são as empresas por detrás de muitos destes investimentos. O seu modelo de negócio passa pela implementação de medidas de eficiência energética através do estabelecimento de um Contrato de Desempenho Energético (CDE) com o cliente. Um CDE consiste num contrato entre a ESE e o cliente, em que ambos recebem uma parte do lucro obtido com as poupanças energéticas, fazendo deste um tipo de contrato de benefício mútuo. Em 2015, as ESE's obtiveram lucros na ordem dos 24 mil milhões de US dólares a nível mundial, e a previsão é que este mercado continue a crescer nos próximos anos e que cada vez existam mais empresas a entrar no sector, de forma direta ou indireta (e.g. através de parcerias com outras empresas). O crescimento da monitorização remota e o controlo e análise de dados faz com que exista uma sinergia entre várias áreas empresariais e está a potenciar o aparecimento de novos modelos de negócio na área, tal como os modelos inovadores propostos no projeto MOEEBIUS, que será retratado no capítulo 2 [6].

## 1.2 – Objetivos

Esta dissertação foi desenvolvida em estreito alinhamento com o projeto MOEEBIUS (Modelling Optimization of Energy Efficiency in Buildings for Urban Sustainability), centrando-se nos modelos de negócio das Empresas de Serviços de Energia (ESE), nomeadamente no desenvolvimento de ferramentas facilitadoras.

O objetivo consiste no desenvolvimento e validação de uma ferramenta de suporte a um dos modelos inovadores de negócio ESE, denominado Serviços de Gestão de Energia (SGE) baseado num Contrato de Desempenho Energético (CDE) melhorado. A ferramenta deverá ser adaptada a determinadas fases do modelo de negócio e deve receber como *inputs* os dados de consumo real e variáveis que potencialmente influenciam o consumo, de modo a permitir realizar a caracterização da *baseline* de consumo<sup>1</sup>, a fazer o cálculo das poupanças energéticas e também a identificar consumos anormais nestes edifícios.

A validação deste modelo de negócio, e da respetiva ferramenta de suporte, será efetuada no edifício da Câmara Municipal de Mafra e aplicado em mais quatro edifícios anónimos, duas escolas e dois edifícios de escritórios. Além disso existe ainda uma comparação entre dois modelos empíricos de previsão de consumos (as redes neuronais e a regressão multilinear) a fim de perceber as vantagens e as desvantagem intrínsecas a cada um dos diferentes modelos previsão.

## 1.3 – Estrutura do trabalho

A presente dissertação está dividida em seis capítulos.

No primeiro capítulo apresenta-se uma breve introdução.

De seguida, no segundo capítulo, é introduzido o trabalho desenvolvido no projeto europeu MOEEBIUS. É efetuada uma ligação entre o trabalho já desenvolvido no projeto e o trabalho que foi desenvolvido nesta dissertação.

No terceiro capítulo é efetuada uma revisão da legislação na área da eficiência energética em edifícios, a nível nacional e a nível europeu. É também efetuada uma revisão dos tipos de modelos de negócio existentes e das etapas dos projetos ESE.

O quarto capítulo pretende introduzir a metodologia de desenvolvimento da ferramenta de suporte ao modelo de negócio, descrevendo todos os processos matemáticos e estatísticos utilizados e também as técnicas de programação.

O quinto capítulo apresenta todos os resultados obtidos com a ferramenta criada para vários edifícios de teste, descreve um tratamento de dados que permite otimizar os resultados e ainda compara os resultados de dois métodos diferentes de previsão de consumos.

Por fim, o sexto capítulo apresenta a conclusão do trabalho desenvolvido expõe algumas sugestões de trabalho futuro.

---

<sup>1</sup> Uma *baseline* de consumo é uma referência que se cria de modo a conseguir efetuar comparações de performance entre o período da *baseline* e outros períodos.

## Capítulo 2 – Projeto MOEEBIUS

O MOEEBIUS - *Modelling Optimization of Energy Efficiency in Buildings for Urban Sustainability* - é um projeto de investigação europeu financiado pelo programa Horizonte 2020. O projeto tem 15 parceiros oriundos de 10 países europeus e o principal objetivo assenta em reduzir a lacuna de desempenho entre o consumo de energia previsto e a energia realmente consumida nos edifícios [3].

Para alcançar esse objetivo, o consórcio do projeto identificou as atuais limitações que conduzem a essa lacuna de desempenho:

- As ferramentas de simulação atuais utilizam muitas simplificações que podem levar a desvios entre a energia simulada e energia consumida.
- A inadaptabilidade dos *Building Information Models* (BIM) em representar as complexidades do edifício real.
- Alterações nos edifícios já durante o período de utilização do mesmo, que não foram contempladas inicialmente.
- Estratégias de controlo pouco eficientes.
- Perda de performance devido a fraca construção ou envelhecimento do edifício.
- Imprecisões meteorológicas.

Para responder a estes problemas o projeto definiu uma estrutura, denominada *MOEEBIUS Framework*, com os seguintes pontos de trabalho:

- Melhorar a avaliação do desempenho energético dos edifícios.
- Alocação precisa de componentes do edifício essenciais à performance energética do mesmo.
- Otimização da performance do edifício em tempo real.
- Otimizar as decisões de reabilitação (*retrofitting*) com base na avaliação do ciclo de vida e do ciclo de custo.
- Gestão em tempo real da carga de pico em edifícios e blocos de edifícios.

O projeto irá desenvolver ferramentas que permitam realizar todos os pontos da *framework* definida.

### 2.1 – Metodologia para definição de novos modelos de negócio ESE

O projeto MOEEBIUS, para o processo de definição de novos modelos de negócio ESE, conduziu inicialmente uma identificação dos *stakeholders* mais relevantes para os mesmos, por forma a avaliar as perspetivas de negócio e os seus respetivos interesses. Dessa análise concluiu-se que os principais *stakeholders* envolvidos num modelo de negócio ESE são os ocupantes dos edifícios, os gestores dos edifícios (*building managers*) e as ESE's.

Através do cruzamento da lista dos *stakeholders* com a *framework* desenvolvida foi possível extrair casos práticos de aplicação, ou seja, ideias que podem ser desenvolvidas e aplicadas num modelo de negócio.

Por fim, foram realizados inquéritos aos *stakeholders* com o objetivo de compreender as suas necessidades.

Ao juntar os casos de aplicação às necessidades dos utilizadores foi possível retirar as ideias dos novos modelos de negócio, que posteriormente foram discutidas com especialistas para compreender o seu potencial e fazer uma definição final dos novos modelos de negócio.



Para cada modelo de negócio foi elaborado um *Business Model Canvas*. O *Business Model Canvas* é um quadro que está dividido por nove secções que representam os pilares de um modelo de negócio. Ao preencher estes pilares é possível descrever, de uma forma menos formal, como irá funcionar o negócio e quais serão todos os seus intervenientes [10]. No Anexo I é possível ver o quadro construído para o modelo de negócio em estudo.

## 2.2 – Novos modelos de negócio ESE

Seguindo a metodologia descrita anteriormente foram desenvolvidos os quatro novos modelos de negócio ESE, que se baseiam em modelos de negócio ESE já existente que, por sua vez, são descritos no capítulo 3. Os novos modelos de negócio são descritos de seguida [10]:

- **Serviços de Gestão de Energia baseados num CDE melhorado** - É uma extensão de um CDE de Poupanças Partilhadas, que além dos parâmetros de energia, tem também em conta parâmetros de saúde e conforto. Além disso, este modelo tenta ultrapassar o obstáculo do financiamento ao se especializar na aplicação de MCE's sem custo ou de baixo custo. A gestão do consumo energético será efetuada por um *Building Management System* (BMS) que irá receber informação em tempo real relativa aos consumos e outros dados do edifício.
- **CDE com base na Condição/Eficiência** – Semelhante a um CDE comum, mas adiciona uma estrutura holística de gestão que, além do BMS, tem em conta a manutenção e reabilitação do edifício. Este contrato terá de ser um contrato mais alongado do que o anterior pois os edifícios apenas necessitam de reabilitação vários anos após serem construídos e isto pode ser uma barreira à aplicação deste modelo como um só.
- **Valorização de edifícios através de eficiência energética** - Este modelo seria destinado a empresas ou pessoas que estivessem a vender ou arrendar edifícios. O seu objetivo seria aumentar o preço de venda ou arrendamento na sequência do aumento da classe energética do edifício.
- **Ferramenta para aumentar a sensibilização dos ocupantes dos edifícios relativamente à eficiência energética** - Consiste no fornecimento de uma interface que estará conectada com o edifício e fornecerá informações em tempo real de consumos e sugestões de poupanças energéticas simples. Espera-se que os utilizadores respondam às sugestões da interface e, consequentemente, reduzam o seu consumo sem a necessidade de mudança de equipamentos.

O modelo que será desenvolvido durante este trabalho será o primeiro modelo apresentado, Serviços de Gestão de Energia baseado num CDE melhorado. É neste contexto que será desenvolvida a ferramenta de suporte.

## 2.3 – Validação dos modelos de negócio ESE

Para validar os novos modelos de negócio foram escolhidas algumas instalações piloto. Estas instalações foram designadas *Living Labs* e vão permitir o teste dos modelos em condições reais e também a verificação da viabilidade destes.

Em Portugal as instalações piloto são três edifícios em Mafra, mais especificamente para o modelo que aqui vai ser desenvolvido, a instalação piloto é o edifício da Câmara Municipal de Mafra. Além de Portugal existem igualmente *Living Labs* na Sérvia e em Inglaterra que irão implementar outros dos modelos de negócio inovadores.

---

## Capítulo 3 – Estado da arte

A revisão do estado da arte começa com a revisão da legislação acerca da eficiência energética a nível nacional e europeu. De seguida é efetuado um resumo dos modelos típicos de negócio das ESE e das fases típicas dos projetos decorrentes dos modelos ESE. É também realizada uma descrição dos métodos de Medição e Verificação (M&V) nos projetos ESE, tal como descritos nos protocolos da área. Finalmente, é efetuada uma revisão dos diferentes métodos que são possíveis de utilizar para a previsão de consumos nos edifícios.

### 3.1 – Legislação em eficiência energética

Em 2010, foi emitida a Diretiva Europeia 2010/31/EU, que aborda a performance energética dos edifícios. A diretiva começa por apresentar a sua motivação, reportando que mais de 40% da energia final consumida na Europa é atribuída aos edifícios. O objetivo da diretiva é incentivar a EE nos edifícios através da definição da metodologia para medir o desempenho energético de um edifício, do estabelecimento de performances mínimas para edifícios novos e existentes e através da regularização das inspeções aos sistemas de consumo intensivo dos edifícios de serviços [7].

Uma das medidas mais destacadas desta diretiva foi a introdução de uma norma que obriga os novos edifícios a serem “*nearly zero energy buildings*” ou nZEB, a partir de 2018 para os novos edifícios públicos e a partir de 2020 para todos os novos edifícios. Foi também avançada uma definição para nZEB, contudo, a definição é vaga o que permitiu aos países definirem o que seria um nZEB nos seus próprios critérios aquando da transposição da norma para a lei nacional [7].

A outra medida que se destaca é relacionada com os certificados de eficiência energética. Além da metodologia holística de cálculo da performance, foram definidos níveis de desempenho mínimos para os edifícios novos e para os edifícios que sofrerem grandes remodelações [7].

Como resposta a esta diretiva europeia surgiu o Decreto-Lei 118/2013 em Portugal. Este decreto-lei divide-se por três secções: Sistemas de Certificação Energética (SCE), Regulamento de Desempenho Energético dos Edifícios de Habitação (REH) e Regulamento de Desempenho Energético dos Edifícios de Comércio e Serviços (RECS) [8].

No SCE foi definida uma escala de A a F, em que todos os edifícios novos têm de pertencer, no mínimo, à classe B- e os edifícios que sofrem grandes intervenções têm de pertencer à classe C. Também foi definido que todos os edifícios que forem colocados no mercado, para venda ou arrendamento, são obrigados a ter o certificado energético [8].

O REH e o RECS apresentam os métodos holísticos de cálculo de performance para os edifícios de habitação e serviços. No REH definem-se valores máximos para as necessidades energéticas, valores mínimos para a qualidade da envolvente, renovação do ar interior e eficiência dos sistemas técnicos. São definidas ainda algumas regras referentes à existência de energias renováveis, com destaque à obrigatoriedade de sistemas coletores solares [8].

O RECS apresenta um método de cálculo ligeiramente diferente em que se agregam os vários parâmetros do edifício num indicador de eficiência energética que terá de ser inferior ao indicador de referência calculado para o mesmo edifício [8].

### 3.2 – Modelos de negócio ESE existentes

Os tipos de contratos realizados pelas ESE's são essencialmente do tipo CDE, ou Contrato de Fornecimento de Energia (CFE). Os CFEs são contratos de fornecimento de energia nos quais a ESE assume a responsabilidade de fornecer ao cliente certos serviços energéticos (ex: produção de energia, climatização, iluminação) a um pré-determinado nível de serviço. Além destes contratos, existem outros como o *Chauffage* que é comparado a um CDE, mas é um tipo de contrato menos complexo onde não existem substituições de equipamentos e tem como principal objetivo o conforto dos utilizadores do edifício [9][10].

Os CDE são contratos onde se procura melhorar a performance energética de um edifício. Atualmente existem bastantes variações deste tipo de contrato. As três modalidades seguintes são as mais comuns:

- O CDE de Poupanças Partilhadas, que tal como o nome indica é um tipo de CDE onde a ESE e o cliente partilham o lucro obtido pelas medidas de conservação de energia (MCE) implementadas pela ESE. Ou seja, a ESE investe o seu próprio capital na implementação de MCE's e a poupança obtida é comparada com uma *baseline* definida antes da aplicação das tais medidas. A duração do contrato varia consoante o investimento inicial e as poupanças obtidas.
- Outro tipo de contrato é o CDE de Poupanças Garantidas, que é um tipo de contrato semelhante ao anterior, mas com um risco maior já que a ESE garante ao cliente um nível mínimo de poupanças, sendo o investimento inicial também suportado pela ESE.
- Por fim, o outro tipo é o CDE com Contrato de Termo Variável. Neste CDE a duração do contrato é flexível e caso as poupanças obtidas sejam inferiores ao esperado o contrato poderá ser estendido.

Os CDE representam risco para as ESE, quer pelo elevado investimento inicial como pela garantia de obtenção de poupanças. De forma a garantir que as poupanças previstas são realmente as obtidas na fase de operação dos edifícios, as ESE deverão ser capacitadas de forma de minimizar este risco. Se o risco for mínimo então as ESE estarão muito mais confortáveis para oferecer contratos mais ousados e atrativos aos clientes. Para tal, têm que ser desenvolvidas e implementadas melhorias nos métodos e ferramentas utilizadas para prever consumos [9][10].

### 3.3 – Fases dos projetos ESE

Um projeto de performance ESE está dividido, tipicamente, em cinco fases que serão descritas no presente subcapítulo [9].

#### 3.3.1 – Desenvolvimento do projeto

A primeira etapa do desenvolvimento do projeto será fazer um estudo prévio de viabilidade, onde a ESE será responsável por apresentar um relatório que demonstra o potencial de poupanças obtidas com a execução do projeto. Este relatório, tipicamente não tem qualquer custo para o cliente e deverá servir como suporte ao cliente na escolha da ESE a executar o projeto, caso este tenha requisitado este estudo a várias entidades.

Após a ESE ser selecionada pelo cliente, é realizado um contrato em que se definem todos os passos ligados à auditoria energética, detalhada à instalação. O custo desta auditoria é, tipicamente, adicionado ao valor total do financiamento dos equipamentos a implementar, assim o cliente só pagará este valor

aquando da obtenção das poupanças energéticas. A auditoria detalhada tem como objetivo caracterizar a forma como é consumida a energia no edifício e permitir a identificação das oportunidades para poupanças energéticas. Na sequência deste estudo, é apresentada uma proposta de projeto de EE ao cliente que, na prática, contém a descrição do conjunto de medidas de melhoria a implementar e as condições de investimento e partilha de poupança.

Finalmente, existindo um acordo entre ambas as partes, deve ser feito um contrato em que se define a sua tipologia (i.e. CDE de poupanças partilhadas), quais os equipamentos que vão ser substituídos, o montante do financiamento, a duração do contrato, a percentagem de partilha de poupanças, a forma de medição e verificação de poupanças e todos os outros detalhes relevantes ao cliente e à ESE [9].

### **3.3.2 – Fase de implementação**

Após o contrato ser assinado, a ESE passa para a implementação de todas as medidas de eficiência identificadas e aprovadas no contrato. As ESE's providenciam, tipicamente, um serviço “chave na mão”, onde a ESE comissiona a instalação dos equipamentos a trabalhadores subcontratados [9].

### **3.3.3 – Fase de aceitação**

Esta fase consiste num período de adaptação do cliente aos novos equipamentos. Durante esta fase as ESE's dão formação aos utilizadores do edifício sobre o método mais eficiente de operar os equipamentos. Também durante esta fase começam as verificações de poupanças por parte da ESE, que se deve certificar de que os equipamentos estão a operar dentro do esperado e caso isso não aconteça devem identificar e corrigir os problemas [9].

### **3.3.4 – Período de *performance***

O período de performance corresponde ao restante período de contrato. Durante esta fase o trabalho da ESE consiste em continuar a fazer a M&V das poupanças e garantir a manutenção de todos os sistemas do edifício [9].

### **3.3.5 – Fecho do projeto**

No fim do projeto todas as contas devem ser acertadas de modo a fechar o contrato assinado. A partir desse período a operação e manutenção dos equipamentos deixa de ser responsabilidade da ESE, pelo que o cliente se deve assegurar que o seu staff está devidamente treinado para operar tais equipamentos [9].

## **3.4 – Medição e Verificação em CDEs**

Para a execução de um contrato de desempenho energético é necessário definir uma estratégia para a M&V de modo a quantificar as poupanças obtidas através das MCE's aplicadas.

As ESE's tendem a seguir os protocolos de aplicação de métodos de M&V, entre esses destaca-se o IPMVP (*International Performance Measurement and Verification Protocol*). O IPMVP é o protocolo mais referenciado em artigos científicos pelo que se pode assumir que é o protocolo base de muitas ESE's [11].

O IPMVP pretende ser acessível aos compradores e vendedores de serviços de M&V. Este protocolo apresenta uma estrutura com dois métodos e quatro opções diferentes, consoante a abrangência das MCE e das medições efetuadas no projeto. Um dos métodos chama-se *Retrofit Isolation Method* e é aplicado

quando o se pretende medir os efeitos de uma única MCE, o segundo método chama-se *Whole Facility Method* e pretende medir os efeitos de um grupo de MCE's, o que significa que as poupanças são avaliadas ao nível de todo o edifício. A tabela 3.1 demonstra as principais características de cada um dos métodos.

Tabela 3.1 – Comparação dos dois métodos de M&V descritos no IPMVP [11].

<i>Retrofit Isolation Method</i>	<i>Whole Facility Method</i>
<ul style="list-style-type: none"><li>▪ Mede o efeito de uma única MCE</li><li>▪ As poupanças não são afetadas por mudanças para lá da fronteira de medição</li><li>▪ Normalmente é necessário instalar contadores de consumo</li><li>▪ Os ajustes à <i>baseline</i> de consumo são simples</li></ul>	<ul style="list-style-type: none"><li>▪ Mede os efeitos em todo o edifício</li><li>▪ As poupanças são calculadas para o edifício</li><li>▪ Usualmente utiliza os contadores de consumo já existentes</li><li>▪ Os ajustes à <i>baseline</i> de consumo são complexos</li></ul>

Depois de definir dois métodos, o IPMVP define que estes dois métodos se dividem por quatro opções, que se definem essencialmente pelos métodos de recolha de dados e quantidade de dados recolhidos. Estas opções são descritas de seguida:

A opção A é denominada *Partially Measured Retrofit Isolation*. Esta abordagem envolve o isolamento do consumo energético do equipamento em que vai ser aplicada a MCE do resto do consumo do edifício. Para esse efeito terá de ser utilizado equipamento de medição que, no entanto, faz apenas uma medição parcial e todos os restantes parâmetros serão estimados. Um exemplo desta abordagem consiste na substituição de uma máquina por outra mais eficiente, para tal seria estimado o consumo desta máquina ao conhecer a sua potência e as suas horas de operação e essa estimativa seria comparada com a medição *in situ* do consumo da nova máquina.

A opção B é denominada *Retrofit Isolation*. Esta abordagem é semelhante à opção A, exceto que nenhum parâmetro pode ser estimado. Assim, todos os parâmetros necessários ao cálculo das poupanças obtidas serão medidos antes e depois da aplicação das MCE's, reduzindo o erro obtido com a opção A mas aumentando a complexidade e os custos associados.

A opção C é denominada *Whole Facility*. Esta abordagem deverá ser escolhida quando existem MCE's aplicadas ao nível de todo o edifício. O consumo será medido antes da aplicação das MCE's para todo o edifício e será comparado com o consumo previsto para o período após a aplicação das MCE's. Para prever o consumo será necessário criar uma *baseline* de consumo do edifício. O problema desta opção é o ruído introduzido pela variabilidade natural do consumo. Para sobrepor esse problema apenas são realizados projetos com poupanças previstas superiores a 10% do consumo total, sendo que, durante o período pós-MCE's deverão ser efetuados ajustes à *baseline* de modo a reduzir esse ruído.

A opção D é denominada *Calibrated Simulation*. Esta abordagem baseia-se na simulação computacional do edifício e pode ser utilizada para calcular a *baseline* de consumo, o consumo pós-MCE ou ambos. Caso se use a simulação apenas para calcular a *baseline*, o consumo pós-MCE deve ser medido. Caso se utilize a simulação apenas para calcular o consumo pós-MCE, o consumo utilizado para criar a *baseline* deve ser medido.

Além do IPMVP existem outros protocolos regularmente referenciados como o FEMP (*Federal Energy Management Program*), o UMP (*Uniform Methods Project*) e o ASHRAE *guideline 14*. Destes protocolos o ASHRAE *guideline 14* é o mais antigo e terá sido a base do IPMVP.

Quanto ao FEMP e ao UMP, são ambos desenvolvidos pelo *United States Department of Energy* e são documentos complementares em determinadas secções, que acabam por ter como base as abordagens descritas do IPMVP. As principais diferenças entre os dois protocolos anteriores são que o FEMP foi desenvolvido especificamente para os edifícios federais dos EUA e o UMP é um documento complementar com métodos de cálculo de poupanças [12].

Mais recentemente, foi desenvolvido o projeto europeu ICP (*Investor Confidence Project*), que é também um guia de métodos de M&V e tem abordagens de M&V semelhantes às do IPMVP, mas distingue-se ao criar metodologias específicas para cada tipo (i.e. residencial, terciário) e dimensão de edifício.

O ICP aborda outro problema que se prende com o financiamento necessário aos projetos. O principal objetivo do ICP é desbloquear o acesso ao financiamento, emitindo certificados que definem um projeto como “investimento seguro” e, assim, reduz a desconfiança sobre este tipo de projetos e atrai potenciais investidores [13].

É importante referir que existem atualmente ferramentas de M&V no mercado, até algo semelhantes à ferramenta desenvolvida nesta dissertação [19][22]. Estas ferramentas não são, porém, ferramentas *open-source* o que significa que não é possível utilizá-las como base para desenvolver a ferramenta que aqui foi desenvolvida.

### 3.5 – Modelos de previsão de consumos energéticos

Apesar desta dissertação ser dedicada a um determinado modelo de previsão de consumo existem muitos métodos diferentes para fazer este tipo de previsões.

Para facilitar a compreensão dos diferentes modelos existentes é possível dividi-los em duas categorias: os modelos de abordagem avançada e os modelos baseados em dados. Os modelos de abordagem avançada fazem a simulação ou emulação<sup>2</sup> do edifício e conseguem prever o seu comportamento no futuro. Os modelos baseados em dados são aqueles que procuram descobrir uma relação entre o consumo e outros dados recolhidos (e.g. variáveis meteorológicas).

#### 3.5.1 – Modelos avançados

Os modelos avançados são modelos mais complexos, pois baseiam-se nos princípios físicos que influenciam a dinâmica dos edifícios, sendo que para a modelação é necessário introduzir um conjunto alargado de dados de entrada, tais como a arquitetura do edifício, os materiais das paredes, os horários de ocupação do edifício, os equipamentos, entre muitos outros. Estes modelos são muito utilizados na fase de conceção do edifício, pois permitem simular diferentes combinações de componentes do mesmo, desde elementos construtivos a sistemas de climatização e avaliar o seu desempenho ao nível energético, auxiliando o processo de tomada de decisões. A grande desvantagem destes modelos é que o seu desenvolvimento é lento e são muito sensíveis a erros e a incertezas associados aos seus dados de entrada,

---

<sup>2</sup> Ao contrário da simulação, que procura recriar/copiar todos os aspetos relevantes de algo e através dessa recriação conseguir produzir resultados, a emulação foca-se apenas na reprodução de resultados, e como tal não necessita de dados tão detalhados.

como por exemplo um erro na potência instalada em iluminação ou a incerteza do número de ocupantes do edifício [16].

Um exemplo de um *software* que permite simular um edifício deste modo é o *EnergyPlus*, desenvolvido pelo *National Renewable Energy Laboratory* [20]. Apesar deste tipo de *software* ter uma grande capacidade de previsão de consumo, a quantidade de detalhes do edifício necessários à simulação faz com que estes *softwares* não sejam o tipo de ferramenta ideal a utilizar num projeto ESE, onde apenas se pretendam implementar MCE's de baixo custo. Por outro lado, quando se fala num edifício de grande escala, onde será possível mudar os sistemas de consumo energético intensivo do edifício então a simulação detalhada deve ser uma opção a considerar porque, tal como foi descrito, permite dimensionar os novos sistemas e, consequentemente, instalar os sistemas mais adequados ao edifício de modo a maximizar as poupanças.

No entanto, o modelo de negócio em causa nesta dissertação é um modelo que pretender ser simples para o cliente, mantendo a precisão pretendida, e apenas se irá focar em MCE's de baixo custo, pelo que se optou por não utilizar os modelos de previsão avançados, mas sim um modelo baseado em dados.

### 3.5.2 – Modelos baseados em dados

Os modelos baseados em dados podem, por sua vez, ser divididos em três subcategorias: os modelos empíricos, as simulações calibradas, e os modelos *gray-box*. Os modelos empíricos são aqueles que comparam o consumo com variáveis independentes. As simulações calibradas são semelhantes aos modelos avançados mas utilizam dados medidos para calibrar a simulação. Os modelos *gray-box* são modelos que comparam o consumo com variáveis independentes e com variáveis dependentes (e.g. as variáveis *time-lagged*, ou atrasadas no tempo) [16]. Na figura 3.1 apresenta-se um esquema que resume os diferentes tipos de modelos de previsão de consumos.

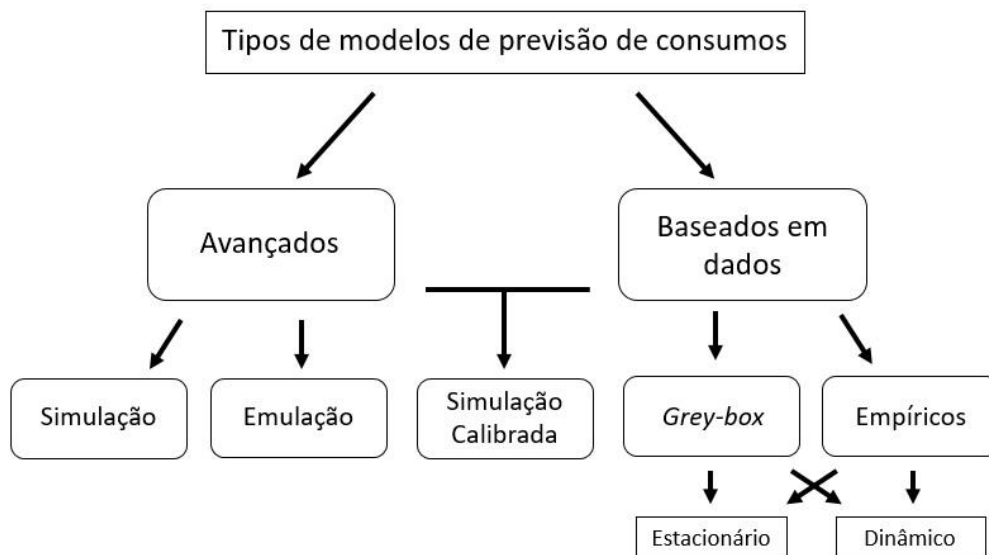


Figura 3.1 - Esquema dos diferentes tipos de modelos de previsão de consumos

As simulações calibradas, mais uma vez, são modelos que não fazem sentido no âmbito do modelo de negócio em estudo devido à sua complexidade. Os modelos *gray-box* foram testados mas irá verificar-se no capítulo 5 que não é possível utilizar este tipo de modelos para o objetivo pretendido.

Restam os modelos empíricos, os quais se podem dividir em duas classes; os modelos empíricos estacionários e os modelos empíricos dinâmicos. Ambos os tipos de modelo podem ser utilizados para o objetivo a que esta dissertação se propõe. A principal diferença entre estas duas classes é que os modelos dinâmicos utilizam a variação do tempo para compreender padrões de consumo. Teoricamente estes modelos têm melhores resultados uma vez que têm mais facilidade na deteção de padrões já que conseguem determinar relações não lineares [16].

Um exemplo de um modelo empírico estacionário é a regressão. Este é o método descrito nos protocolos de M&V por ser um método simples em que é possível obter bons resultados. No âmbito desta dissertação foi utilizada a regressão linear de multivariável, ou regressão multilinear, essencialmente por ser o método descrito nos protocolos. Numa tentativa de obter melhores resultados foram feitas algumas melhorias a este método simples, ao adicionar outros dois métodos complementares (*Change Points* e *Variable Base Degree Day*) e também ao fazer um tratamento de dados personalizado, que deverá ser efetuado antes da aplicação dos dados na ferramenta.

Foram também testados modelos empíricos dinâmicos, nomeadamente as redes neuronais, de modo a compreender a diferença entre os resultados destes modelos e do modelo construído. As redes neuronais são um método de previsão extensamente utilizado por todas as áreas científicas que necessitam de prever situações futuras. O seu método de funcionamento baseia-se num cérebro humano ao utilizar “neurónios” que vão aprender e com essa aprendizagem são criados pesos entre as ligações efetuadas que estabelecem as relações futuras. Algumas das aplicações das redes neuronais nos edifícios são, além da previsão dos consumos energéticos, a previsão das necessidades de aquecimento, de arrefecimento, da carga de iluminação, entre outros [17][21].



## Capítulo 4 – Metodologia

### 4.1 – Desenvolvimento do modelo de negócio

O primeiro passo para desenvolver o modelo de negócio “Serviços de Gestão de Energia baseado num CDE melhorado” será defini-lo de uma forma mais extensa e intensiva, de modo a que se compreendam bem quais as diferenças em relação ao modelo tradicional e quais as suas principais características inovadoras.

O modelo “Serviços de Gestão de Energia baseado num CDE melhorado” tem como base o modelo tradicional CDE de Poupanças Partilhadas, isto porque a ideia será compartilhar as poupanças obtidas entre a ESE e o cliente, durante a duração do contrato. É, no entanto, um modelo muito diferente do tradicional; enquanto este último passa essencialmente por identificar equipamentos que possam ser substituídos por outros com melhor eficiência e daí obter lucros, o modelo a ser implementado tenta evitar os elevados investimentos.

Segundo a definição do MOEEBIUS, o modelo só deve implementar substituições de equipamentos cujo tempo de retorno do investimento seja igual ou inferior a um ano. As principais MCE's a efetuar serão aquelas que não terão qualquer custo como por exemplo a mudança de *setpoints*. Cabe à ESE descobrir potenciais poupanças durante a auditoria. Caso não exista potencial a ESE deve informar o cliente e cessar as atividades no local.

Outra das características inovadoras deste modelo é a adição de parâmetros de saúde e conforto, além dos habituais parâmetros de energia. Os parâmetros adicionados estão relacionados com o conforto térmico e visual e com a qualidade do ar interior. Todos estes parâmetros são de elevada importância para os clientes e ao inclui-los no modelo estamos a caminhar no sentido correto para a sua satisfação.

Para conseguir implementar MCE's sem custo e verificar se estas estão a surtir efeito será necessário utilizar um BMS. Este sistema deverá receber informações em tempo real provenientes de sensores que serão utilizados para registar consumos, temperaturas interiores, entre outros.

O principal custo na implementação deste modelo acaba por ser o tempo despendido pela equipa de engenheiros. Além do tempo despendido na realização da auditoria e do contrato ainda existe o trabalho por detrás do desenvolvimento do BMS e da sua personalização para cada caso. A realização de tarefas por meio remoto e a automação podem ser úteis para diminuir o tempo despendido em cada caso.

Outra componente importante deste modelo é a formação dos utilizadores. De modo a garantir que as poupanças ocorrem é necessário que o modelo inclua uma componente pedagógica na qual se devem ensinar os utilizadores a operar os equipamentos da melhor forma e outras boas práticas em termos energéticos.

### 4.2 – Ferramenta de suporte

O consórcio do MOEEBIUS realizou uma série de inquéritos a especialistas acerca das suas opiniões sobre este modelo de negócio, entre os quais 77% dos inquiridos consideraram que este modelo é inovador. Os restantes 23% acharam que já existem ESE's a fazer contratos semelhantes e que a inovação neste modelo irá depender dos métodos de cálculo de poupanças utilizados [10].

Para tal será desenvolvida uma ferramenta de suporte ao modelo de negócio, denominada “MVtool”. A MVtool irá calcular as poupanças, de onde advém o lucro da ESE, mas também funcionará como um BMS simplificado ao identificar consumos anormais nos edifícios que podem ser provocados por más práticas dos utilizadores ou por equipamentos defeituosos. No anexo II existe um guia de aplicação da MVtool.

O método de cálculo da *baseline* descrito neste trabalho foi já descrito em artigos da área pelo que a principal inovação que poderá existir é a utilização da ferramenta como um BMS, mas para isto terá de existir uma capacidade de captação e integração em tempo real dos dados relevantes ao consumo do edifício.

Atualmente já existem ferramentas que permitem fazer a caracterização da *baseline* de consumo e a identificação de consumos anormais, por isso coloca-se a questão da vantagem de utilização desta ferramenta. Se compararmos esta ferramenta com *softwares* de grandes capacidades como o *MS Excel*, *Matlab* ou *Minitab* é fácil compreender a diferença. Com o *MS Excel* seria necessário muito tempo e alguns conhecimentos de operações matriciais, uma vez que o *MS Excel* não consegue fazer automaticamente algumas das operações realizadas. Com o *Minitab* teríamos a desvantagem de fazer individualmente cada passo, o que seria menos prático para o utilizador. Já o *Matlab* permite fazer as mesmas operações que a MVtool caso seja construído um *script* para tal, porém a razão para não se ter utilizado este *software* prendeu-se mais com o seu custo e não com as suas capacidades.

Portanto, o verdadeiro desafio consiste na comparação desta ferramenta com outras já desenvolvidas por ESE's, tal como a Dexmatech (ver no capítulo 5) [19]. Porém, é difícil identificar quais os métodos de cálculo intrinsecamente utilizados por essas ferramentas. Admitindo que os resultados são equiparáveis para a ferramenta desenvolvida e aquelas já existentes no mercado, a grande vantagem da MVtool é a quantidade de resultados e a adaptabilidade ao modelo de negócio em estudo. Por exemplo, a ferramenta da Dexmatech permite estimar as poupanças, mas não o faz automaticamente com o mesmo tipo de regressão que a MVtool; para obter este tipo de resultado, a Dexmatch recorre a outro *software* e posteriormente compara os resultados utilizando a sua ferramenta.

Ainda na gama das ferramentas que permitem caracterizar a *baseline*, encontra-se a ferramenta desenvolvida pela Noesis Esta ferramenta mais avançada permite obter os mesmos resultados que a MVtool, sendo que oferece uma interface mais *user friendly* e permite personalizar os gráficos. As duas grandes desvantagens são o facto de a ferramenta não permitir a regressão com variáveis além das meteorológicas e ser exclusiva para clientes da Noesis, tendo, portanto, um custo associado [22].

Mesmo a ferramenta da Dexmatech é uma ferramenta menos prática para os objetivos pretendidos e apresenta um custo mensal de 1000 €, o que constitui uma desvantagem determinante em muitos casos. Assim, fica claro que o desenvolvimento da MVtool era essencial para a aplicação do modelo de negócio em estudo, já que este se baseia em medidas de baixo custo e na consecução do maior valor possível de poupanças.

#### 4.2.1 – *Baselining*

Para determinar a rentabilidade de qualquer projeto de EE, criar uma *baseline* é fundamental. A *baseline* de consumo será o consumo base antes da aplicação de qualquer MCE.

Contudo, o consumo dos edifícios é muito variável, dependendo do tamanho do edifício, da sua ocupação, das atividades que ocorrem no seu interior, do clima no exterior, entre outros. Para a definição da *baseline* é necessário compreender quais destes fatores serão determinantes para as flutuações do consumo no edifício em causa.

Para começar a definir a *baseline* é necessário perceber, também, quais são as fontes de energia do edifício. A mais óbvia será a eletricidade comprada à rede elétrica, mas também se poderá abordar o consumo de gás natural ou propano, a existência de fontes de energia elétrica renovável ou não renovável no edifício ou até o calor proveniente de uma rede de *district heating*. Ou seja, o consumo energético será a diferença entre a eletricidade comprada e gerada *on-site*. A energia térmica deverá ficar à parte uma vez que não se pode somar à energia elétrica.

Após a identificação das fontes de energia no edifício deve-se obter os dados de consumo, com uma periodicidade horária de preferência, e também os dados das variáveis que afetam o consumo do edifício com a mesma periodicidade. Com estes dados deverá ser feita uma regressão analítica de modo a obter uma equação do consumo energético em função das outras variáveis. Como normalmente existem várias variáveis, o tipo de regressão a fazer deverá ser uma regressão multilinear, mas métodos mais complexos podem ser aplicados. O método utilizado para fazer a regressão será um programa escrito em *Python* que posteriormente deverá correr como um executável para conveniência dos futuros utilizadores.

É importante ter em atenção o erro de cada variável individualmente já que um erro elevado de uma variável indica que esta não se adequa bem ao consumo logo não deverá ter influência neste. Após a regressão, deverá proceder-se à eliminação de variáveis com elevado *p-value* e posterior repetição da regressão até todos os valores do *p-value* serem baixos. O *p-value* é o resultado de um teste estatístico e representa a significância daquela variável no resultado final.

Recorda-se que o preço da eletricidade comprada à rede geralmente não é fixo ao longo do dia mas sim variável de acordo com as ofertas propostas em mercado ibérico. Nesses casos existe potencial para fazer *load shift* de modo a obter poupanças não ao nível de energia, mas ao nível financeiro. Porém, para conseguir prever poupanças relativas ao *load shift* é necessário que os dados tenham uma periodicidade horária para prever as poupanças hora a hora. Assim é possível detetar se houve uma mudança no horário de uso das cargas.

#### 4.2.2 – Descrição matemática

Para descobrir os coeficientes que irão criar a *baseline* foram realizadas operações matriciais do tipo  $y=mx+b$ , onde  $x$  é a matriz das variáveis e  $y$  é o vetor dos dados de consumo de energia.

Para descobrir o declive far-se-ia o seguinte:

$$m = \frac{y - b}{x} = (y - b) \cdot x^{-1} \quad \text{Equação 4.1}$$

Quando se faz uma regressão com matrizes é possível substituir o termo de intersecção no eixo vertical por uma coluna com valores igual a 1 na matriz  $x$  pois o produto externo de matrizes resulta no somatório dos produtos de cada termo e, assim, o termo de intersecção passa a estar dentro da matriz  $m$ . Desse modo fica-se com:

$$\begin{bmatrix} b \\ m \end{bmatrix} = yx^{-1} \quad \text{Equação 4.2}$$

O problema para fazer esta operação com matrizes é que apenas é possível descobrir a matriz inversa de uma matriz quadrada, o que dificilmente irá ocorrer na matriz  $x$ . Para contornar este problema é possível

descobrir a matriz pseudoinversa. A matriz pseudoinversa é uma matriz inversa parcial que tem algumas das mesmas propriedades que a matriz inversa mas pode ser aplicada em matrizes não quadradas [18].

$$X^+ = (X^T X)^{-1} X^T \quad \text{Equação 4.3}$$

A multiplicação pela matriz transposta permite criar uma matriz quadrada que, por sua vez, permite descobrir a matriz pseudoinversa. A matriz pseudoinversa será uma matriz com dimensões tais que será possível fazer o produto com o vetor  $y$ .

Para facilitar a compreensão desta operação pode-se olhar para as dimensões das matrizes, lembrando apenas algumas das propriedades do produto de duas matrizes. Primeiro, só é possível fazer o produto externo entre duas matrizes quando o número de colunas da primeira matriz for igual ao número de linhas da segunda matriz. Segundo, a matriz resultado vai ter o mesmo número de linhas que a primeira matriz e o mesmo número de colunas que a segunda matriz.

Sabe-se que  $m$  tem de ser uma matriz do tipo  $(m \times 1)$ , onde  $m$  é o número de variáveis mais um, pois deve haver um coeficiente para cada variável e mais um termo independente que é a interseção com o eixo vertical. Sabe-se também que o consumo de energia corresponde a uma matriz  $(n \times 1)$ , onde  $n$  é o número de observações realizadas, e que as variáveis devem ter uma matriz do tipo  $(n \times m)$ . Assim, tem-se:

$$\begin{aligned} (m \times 1) &= (m \times n)(n \times m)(m \times n)(n \times 1) = (m \times m)(m \times n)(n \times 1) \\ &= (m \times n)(n \times 1) = (m \times 1) \end{aligned} \quad \text{Equação 4.4}$$

Estes coeficientes (vetor  $B$ ) são a parte mais relevante do programa pois são, de forma prática, a *baseline*.

### 4.2.3 – Métodos Estatísticos

Para determinar a qualidade e validar os resultados obtidos, o programa vai calcular três estatísticas de qualidade de resultados: o coeficiente de determinação, o coeficiente de variação, e a probabilidade de significância.

O *p-value*, ou probabilidade de significância, permite descobrir se existe uma boa relação entre cada variável e o consumo o que, por sua vez, permite efetuar os passos da regressão através da eliminação de variáveis com *p-values* acima do valor proposto pelo IPMVP.

Numa explicação mais completa, o *p-value* reflete a probabilidade de a hipótese nula ser verdadeira, ou seja, no âmbito desta dissertação a hipótese nula seria a inexistência de uma relação entre o consumo energético e a variável a ser testada. Se a probabilidade de a hipótese nula ser verdadeira for maior que 5% então considera-se que essa variável não pode ser utilizada na regressão pois esta pode não ter relação com o consumo energético [25].

Para descobrir o *p-value* é necessário entender o teste-*t*. O teste-*t* é um teste utilizado para rejeitar a hipótese nula. Dada uma amostra pode-se dizer que a hipótese nula será:

$$H_0: \mu = \mu_0 \quad \text{Equação 4.5}$$

Sendo que  $\mu$  será a média (para testar um afastamento à média) e  $\mu_0$  será o valor para o qual se pretende testar [24].

Para rejeitar a hipótese nula, a média da amostra ( $\bar{X}$ ) deveria estar afastada de  $\mu_0$ . No entanto, para saber o afastamento mínimo necessário de forma a rejeitar a hipótese nula calcula-se a variância.

A variância da amostra é dada por:

$$S^2 = \frac{\sum_{i=1}^{df+1} (X_i - \bar{X})^2}{df} \quad \text{Equação 4.6}$$

Onde o dividendo é o somatório do quadrado da diferença entre cada valor da amostra e a média da amostra. Aplicando ao caso de estudo o dividendo vai corresponder ao somatório do vetor dos residuais, que é a diferença entre os resultados reais (o consumo de energia) e os resultados previstos (o produto dos coeficientes com as variáveis). Na teoria deveriam de ser iguais, mas devido às operações matriciais, estes resultados, vão ser ligeiramente diferentes. Os residuais vão então corresponder a um vetor ( $E$ ) com as mesmas dimensões que o vetor do consumo de energia [24].

Para rejeitar a hipótese nula é necessário que:

$$\frac{|\bar{X} - \mu_0|}{\text{Var}(B)} \gg 0 \quad \text{Equação 4.7}$$

Sendo  $\text{Var}(B)$  a variância do polinómio calculado [24].

A lógica por detrás desta equação é que se pretende que a média da amostra seja muito diferente de  $\mu_0$  mas ao mesmo tempo procura-se uma variância baixa que justifique que o afastamento entre  $\bar{X}$  e  $\mu_0$  é suficiente.

A variância de  $B$  é dada por:

$$\text{Var}(B) = \sqrt{S^2 \cdot (X^T X)^{-1}} \quad [\text{diagonal principal}] \quad \text{Equação 4.8}$$

Note-se que a variância de  $B$  deve ser um vetor com as mesmas dimensões de  $B$ , mas aparentemente parece ser uma matriz. O que ocorre é que o produto da variância da amostra deve ser efetuado apenas com os elementos da diagonal principal da matriz uma vez que, em termos matemáticos, os valores da diagonal vão corresponder aos valores do erro padrão quadrado [26].

O valor  $t$  vai permitir caracterizar o afastamento da equação 4.7, que se irá refletir no  $p$ -value, e é dado por:

$$t = B/\text{Var}(B) \quad \text{Equação 4.9}$$

Onde se substitui  $\bar{X}$  por  $B$  já que o objetivo é descobrir o afastamento dos coeficientes calculados e não um afastamento à média, e desaparece  $\mu_0$  uma vez que a hipótese nula é não existir uma relação entre a variável e o consumo, o que ocorre se o valor do coeficiente ( $B$ ) for igual a zero [26].

O valor  $t$  é o valor utilizado no teste- $t$ , que juntamente com os graus de liberdade permite obter o  $p$ -value. Para determinar o  $p$ -value utiliza-se a distribuição  $t$ -student, na qual se admite que o valor  $t$  é o limite superior e assim descobre-se a percentagem fora do limite nesta distribuição. Depois multiplica-se por dois (uma vez que existem duas “caudas”, ou seja, existe um lado positivo e negativo na distribuição) [25]. Isto observa-se na figura 4.1, onde a área azul corresponde à área para lá do valor  $t$  calculado e o  $p$ -value será o dobro da percentagem desta área azul.




Figura 4.1 – Representação da distribuição  $t$ -student.

Outra estatística utilizada é, utilizando a mesma distribuição  $t$ -student, os coeficientes de  $B$  para um intervalo de confiança de 95%. Para isso utiliza-se o processo inverso do que foi utilizado para descobrir o  $p$ -value. Através do intervalo de confiança sabe-se que vai ficar 2.5% fora da distribuição em cada cauda, daí é possível retirar os valores  $t$ .

Utilizando a equação 4.9 consegue-se retirar um vetor de coeficientes que reflete os desvios à média tendo em conta a variância e o intervalo de confiança utilizados. Para obter os coeficientes da *baseline* com o intervalo de confiança definido há que fazer:

$$B_{superior} = B + B_{desvio} \quad \text{Equação 4.10}$$

$$B_{inferior} = B - B_{desvio} \quad \text{Equação 4.11}$$

Estes valores são um dos *outputs* da ferramenta e a razão para tal é que é possível utilizar este polinómio, em conjunto com os *Change Points*, (estatística explicada de seguida) para identificar ajustes à *baseline*. Isto irá permitir ao utilizador verificar se o consumo se encontra dentro do intervalo e quando está fora do intervalo o utilizador deverá verificar se existe alguma justificação para isso. Tanto pode ser uma variação regular como pode haver alguma diferença no edifício que fará com que o utilizador da ferramenta tenha de fazer um ajuste não rotinado, que é um tipo de ajuste que deverá de ser realizado quando as condições em que foi criada a *baseline* mudam sem a afetar, mas afetando o consumo. Um exemplo será a modificação do uso do espaço, imaginando que o espaço era utilizado como área de receção durante o período da *baseline* mas agora é utilizado como área de trabalho. Pode-se imaginar que isso irá afetar o consumo do edifício pois deverão ser ligados mais equipamentos elétricos à rede elétrica e a ocupação também será diferente, o que irá afetar a climatização.

Para o utilizador projetar este polinómio necessita de multiplicar este pelo valor de poupanças obtido de forma a o adaptar ao período das poupanças. Este método de transposição dos limites da *baseline* não é um método descrito nos protocolos e embora seja feito em algumas ferramentas de M&V não foi possível verificar que este seja o método utilizado para a realizar. Assim sendo, este método deverá ser utilizado com cautela e apenas a utilização em casos práticos poderá dizer se é, ou não, um bom indicador da necessidade de implementar ajustes na *baseline*.

Fora dos testes  $t$  foram utilizados dois indicadores de erro. Um deles foi o coeficiente de variação do desvio da raiz da média ao quadrado, ou CV[RMSD]. O desvio da raiz da média ao quadrado, ou RMSD, é dado por:

$$RMSD = \sqrt{\frac{\sum E^2}{df}} \quad \text{Equação 4.12}$$

Este indicador permite visualizar o afastamento entre os valores reais e os previstos sem se analisar todo um conjunto de dados. Um valor elevado significa que existe um grande afastamento e vice-versa. O problema é que não se sabe ao certo o que é um valor muito elevado ou não por isso opta-se por calcular o CV[RMSD], que é dado por:

$$CV[RMSD] = \frac{RMSD}{\bar{Y}} \quad \text{Equação 4.13}$$

Sendo que  $\bar{Y}$  é o valor médio da amostra dos valores reais de consumo energético, no caso desta dissertação. O que o coeficiente de variação permite fazer é normalizar o RMSD. Esta percentagem pode agora ser comparada com os limites definidos nos protocolos que, para este caso apontam um valor máximo de 20%. Estes valores limites protocolares não são valores estáticos pois a experiência pode demonstrar que um resultado é bom o suficiente apesar de ultrapassar um destes limites [24].

Por fim, foi calculado também o coeficiente de determinação ( $R^2$ ), tal como demonstrado na equação 4.14. Este, por sua vez, foi convertido ao coeficiente de determinação ajustado ( $R^2_{ajst}$ ) devido à regressão utilizar múltiplas variáveis.

$$R^2 = 1 - \frac{\sum E^2}{\sum Y^2} \quad \text{Equação 4.14}$$

$$R^2_{ajst} = 1 - (1 - R^2) \cdot \frac{m - 1}{df} \quad \text{Equação 4.15}$$

O coeficiente de determinação é uma medida da proporção de variação em resposta às variáveis utilizadas. Um valor elevado demonstra que a variação nos valores reais é explicada pelas variáveis, um valor pequeno indica que pouca variação é justificada pelas variáveis utilizadas [25].

O coeficiente de determinação é semelhante ao RMSD, sendo que ambos utilizam a soma dos quadrados do vetor dos residuais. A diferença é que o coeficiente de determinação faz imediatamente uma normalização ao dividir esse valor pela soma dos quadrados do vetor de consumo. Isto significa que o coeficiente de variação do RMSD avalia a magnitude do erro da previsão [25].

Quando se trata de uma regressão multilinear a utilização do coeficiente de determinação ajustado justifica-se com o aumento desde indicador com cada variável adicionada, independentemente da nova variável ter, ou não, uma boa relação com os valores reais. Ao dividir o número de observações pelos graus de liberdade obtém-se um valor maior que um, que será tanto maior quanto mais sejam as variáveis utilizadas. Este valor vai por sua vez permitir a redução do coeficiente de determinação com o aumento do número de variáveis, permitindo assim compensar o outro efeito de aumento, que não é real [26].

Finalmente, o programa aplica também o modelo *Change Point*. Este modelo para detetar mudanças de padrão começa por formar um gráfico CUSUM (por extenso: *Cumulative Sum*), que representa a soma cumulativa do vetor dos consumos reais, neste caso de estudo. Para tal é necessário aplicar a seguinte fórmula:

$$CS_i = CS_{i-1} + (X_i - \bar{X}) \quad \text{Equação 4.16}$$

Onde  $X$  é o vetor dos consumos,  $CS$  é o vetor *Cumulative Sum*,  $i$  é a dimensão do vetor  $X$  e para  $i=0$   $CS=0$  [25].

Para identificar o *Change Point* (CP):

$$CP = \max(|CS|) \quad \text{Equação 4.17}$$

Ou seja, o *Change Point* corresponde ao ponto mais afastado do zero no vetor CUSUM [25].

Para confirmar a existência deste *Change Point* é necessário fazer um processo denominado de *bootstrap*. De uma forma simples, este *bootstrap* corresponde à reorganização aleatória do vetor do consumo. Após o *bootstrap* volta-se a utilizar a equação 4.16. Este processo deve ser repetido várias vezes sendo que quanto maior for o número de repetições melhor será a precisão do valor de confiança gerado.

Para gerar a percentagem de confiança devem então ser aplicadas as seguintes equações:

$$CS_{dif} = CS_{max} - CS_{min} \quad \text{Equação 4.18}$$

Esta equação deve ser aplicada ao vetor  $CS$  original e a todos os vetores  $CS$  provenientes dos *bootstrap*. Diga-se que  $A$  é o número de vezes que  $CS_{dif}$  dos bootstraps é maior que  $CS_{dif}$  original e  $C$  é o número de *bootstraps* realizado, então:

$$\text{Nível de confiança [\%]} = \frac{A}{C} \times 100 \quad \text{Equação 4.19}$$

Apenas devem ser considerados válidos os *Change Points* para os quais o nível de confiança é maior que 95% [25].

Finalmente, caso se pretenda calcular *Change Points* de nível inferior (com menos significância) divide-se o vetor dos consumos no *Change Point* identificado previamente e repete-se todo o processo para os dois novos vetores.

#### 4.2.4 – Programa desenvolvido

A linguagem de programação utilizada para escrever o programa foi o *Python*. A escolha do *Python* ocorreu por vários motivos, sendo que o principal foi o facto de ser gratuito, algo que está a atrair muitas pessoas para esta linguagem de programação. Depois, e até porque o *Python* não é a única linguagem de uso gratuito, a escolha justifica-se também por esta ser considerada uma boa linguagem para análise de dados, tem uma das maiores comunidades a nível mundial, o que facilita a partilha de conteúdos e o *debugging* [23].

Apesar das vantagens do *Python*, este tem algumas fragilidades, sendo a principal a velocidade de execução. No programa criado esta é uma falha evidente pois um programa simples como este ainda



demora alguns segundos a executar. Neste caso específico esta dificuldade poderia ser ultrapassada pois a morosidade de execução prende-se com a importação das bibliotecas necessárias. Seria possível substituir algumas das bibliotecas utilizadas por outras com menos complexidade e com o mesmo efeito e assim acelerar significativamente a execução do programa.

O *Python* também não é uma das linguagens com mais bibliotecas, o que é um obstáculo aquando de fazer tarefas muito específicas. Apesar desta desvantagem se estar a desvanecer com o aumento da popularidade do *Python*, ainda é possível encontrar vários obstáculos que poderiam ser resolvidos se existissem muitas bibliotecas para efeitos semelhantes, o que permite muitas vezes fazer *debugging* ou ultrapassar erros. Uma biblioteca é um conjunto de rotinas que o programador utiliza para não ter de escrever esse código, na prática funciona como uma função que se chama sempre que necessário e com os *inputs* corretos fornece *outputs* que facilitam a escrita. Normalmente as rotinas desenvolvidas nas bibliotecas são extremamente complexas, pelo que as bibliotecas facilitam o desenvolvimento de novos programas e ferramentas aos programadores.

O programa desenvolvido inclui quatro tarefas complexas, para as quais teriam de ser utilizadas bibliotecas específicas. As mais evidentes são as operações matriciais, tal como se vê no capítulo da descrição matemática, e dos métodos estatísticos.

Para fazer as operações matriciais foi utilizada a biblioteca *NumPy* e para fazer os testes estatísticos *t-student* foi utilizado o *SciPy*. A biblioteca *NumPy* é uma biblioteca muito leve e adequada para o que se pretende realizar, mas a biblioteca *SciPy* é uma biblioteca muito extensa, da qual apenas é necessária uma parte muito pequena, o que vai aumentar a complexidade do programa de forma desnecessária. Uma possibilidade seria descobrir o código correspondente a este teste, dentro da biblioteca, e aplicá-lo diretamente no código. Isto seria juridicamente legal uma vez que o *Python* e todas as suas bibliotecas são *open-source*, o que significa que é legalmente permitido utilizar partes de bibliotecas que tenham sido desenvolvidas por outras pessoas.

Outra biblioteca foi a *Pandas*, a *Pandas* é a maior biblioteca utilizada (i.e. tem muitas funcionalidades) e é exclusiva para análise de dados. À semelhança do sucedido com a *SciPy*, a biblioteca *Pandas* foi somente utilizada para manipular as matrizes que por sua vez foram utilizadas com o *NumPy* e para importar e exportar dados.

A última biblioteca utilizada foi a *Matplotlib*, que é permite criar gráficos.

Após a importação das bibliotecas o programa terá de receber um *input* dos dados para os quais irá fazer a regressão. Com o auxílio da *Pandas* é realizada esta importação e um tratamento dos dados importados de forma a permitir as operações matriciais.

Dentro de uma função são executadas todas as operações descritas no capítulo 4.2.2 onde são obtidos os resultados do polinómio e também os resultados dos testes estatísticos. No entanto, a regressão terá de ser repetida até os *p-values* estarem dentro do limite, pelo que esta função vai estar presente dentro de um ciclo que a repete até obter todos os valores dentro dos limites.

Foi então criada mais uma função que tem o único propósito de excluir as variáveis com os *p-values* maiores que 5%. Esta função vai ser executada dentro do mesmo ciclo que a função de cálculo e assim este ciclo vai calculando os valores e eliminando imediatamente as variáveis indesejadas.

É neste ponto que o programa irá perguntar ao utilizador se quer calcular os graus-hora. Caso o utilizador já tenha usado este *input* deve dizer que não e caso pretenda utilizar a temperatura exterior, também deve dizer que não. Se a resposta do utilizador for afirmativa então o programa pergunta em que coluna

do ficheiro de *input* se encontra a temperatura exterior e utiliza um método iterativo para descobrir quais os *setpoints* que produzem o melhor coeficiente de determinação. A ferramenta transmite ao utilizador quais foram os *setpoints* utilizados para o utilizador calcular os graus-hora manualmente se isso lhe for conveniente.

O programa vai calcular duas vezes os *Change Points*, uma vez para o período de *baseline* e outra para o período de análise de poupanças. Os *change points* são bons indicadores para identificar consumos excecionais que poderão ser removidos, melhorando assim o modelo criado. Nunca serão apresentados mais do que três *change points* uma vez que este método serve para detetar diferenças de padrão e quando aplicado a períodos pequenos, ele vai detetar variações naturais. Também será apresentada uma percentagem ao lado da linha do ficheiro de *input* na qual ocorre a mudança. Essa percentagem é a confiança da existência de um *change point*.

Neste momento o programa cria um *output* com os resultados do polinómio e pergunta ao utilizador se deseja calcular as poupanças. Para isto o programa vai ler outra série de dados fornecidos pelo utilizador que deverão corresponder aos dados do consumo e variáveis após a aplicação das MCE's. O programa irá criar uma previsão de consumo tendo em conta as novas variáveis e calcular a percentagem de poupanças que foi obtida. De seguida apresenta-se a matemática por detrás deste passo:

$$\text{Poupança obtida} = \bar{Y}_{new} - \bar{X}_{new} \cdot B \quad \text{Equação 4.20}$$

$$\text{Poupança obtida [\%]} = \frac{\text{Poupança obtida}}{\bar{Y}_{new}} \quad \text{Equação 4.21}$$

Nestas fórmulas  $\bar{X}_{new}$  corresponde à nova matriz das variáveis e  $\bar{Y}_{new}$  corresponde ao novo vetor de consumo. O vetor dos resultados do polinómio é o mesmo que foi utilizado nos cálculos anteriores.

Por fim o programa vai recorrer à biblioteca *Matplotlib* para traçar alguns gráficos. Devido ao grande número de dados que poderá ser introduzido, o programa fará os gráficos apenas para duas semanas, uma semana de Verão e uma semana de Inverno. A recomendação é que o utilizador utilize dados horários durante o período de um ano porque, caso isso não aconteça, as semanas podem não corresponder aos períodos de Inverno e Verão referido e o utilizador poderá não se aperceber. A computação por detrás destes gráficos consiste na extração da segunda e da vigésima sexta semana do ano. Na versão atual do programa tem-se então os gráficos automáticos otimizados para uma série de dados anual. Caso seja inserida uma série de dados que não corresponda a um ano então os gráficos podem não corresponder a semanas completas e será difícil compreender qual é o período que está a ser representado.

#### 4.2.5 – Validação

Para testar a MVtool foram utilizados cinco edifícios, dos quais são conhecidos os consumos de, pelo menos, dois anos e também são conhecidas as variáveis meteorológicas referentes a esses mesmos anos. Isto permite criar uma *baseline* de consumo referente a um dos anos e comparar os resultados com o outro ano.

O único problema nestes testes é que não foram aplicadas MCE's entre os anos em estudo, mas mesmo assim é possível fazer uma comparação na qual o objetivo será atingir um valor de poupanças perto dos 0%.

Teoricamente nem será necessário fazer esta comparação para saber se a regressão está a criar uma boa previsão de consumo pois, desde que os indicadores de erro respeitem os limites dos protocolos e que seja assegurado que as condições de operação do edifício não sejam modificadas de um ano para o outro então os resultados obtidos estarão a demonstrar uma boa relação entre as variáveis e o consumo, logo existirá uma boa previsão das necessidades energéticas do consumidor.

Para garantir que as condições de operação do edifício não mudam de um ano para o outro, a ferramenta utiliza um intervalo de confiança que, caso seja ultrapassado, irá alertar o utilizador para uma mudança. Os *Change Points* funcionam ao mesmo tempo, e possivelmente irão corroborar a existência da mudança no consumo. Nesse momento o gestor do edifício terá de verificar o que se passa. Pode ser um evento normal que esteja a causar uma falha na previsão de consumo e se tal ocorrer não deve ocorrer um ajuste da *baseline*, até porque o intervalo de confiança tem uma margem de erro. Mas se o intervalo de confiança estiver constantemente a ser ultrapassado então cabe ao gestor do edifício verificar as razões para tal e fazer um ajuste na *baseline* para esse consumo. Um exemplo será a contratação de novos funcionários uma vez que aumenta o arrefecimento necessário, aumenta o número de equipamentos ligados e se a ocupação não for uma variável utilizada nesse edifício, isto fará rapidamente com que o consumo esteja fora do intervalo previsto.

O problema é que estes testes não são uma verdadeira validação pois mesmo que os resultados obtidos sejam positivos, não existe maneira de garantir que estes são os resultados que deveriam ter sido realmente obtidos. A verdadeira forma de validar a ferramenta será fazer uma comparação com dados já testados, de modo a analisar se os resultados obtidos são os mesmos.

Para fazer a validação foram comparados os resultados obtidos com os resultados de uma ESE que opera com mais de 200 parceiros espalhados por 33 países, chamada DexmaTech. Esta ESE foca-se no fornecimento de um *software* de gestão de energia e por isso também procura fazer previsões de consumos e cálculos de poupanças obtidas.

Aplicando os dados de um edifício exemplo fornecido pela ESE na MVtool, obtêm-se exatamente os mesmos resultados do polinómio resultante e dos indicadores de erro obtidos que a ESE, como se pode ver na tabela 4.2. Os *inputs* usados em ambos os casos foram exatamente os mesmos.

Tabela 4.1 – Comparação de resultados obtidos pela DexmaTech e pela MVtool para o mesmo grupo de dados.

Resultados obtidos pela DexmaTech
$Y_{previsto} = 2109.2 + 174.15 \cdot CDD + 0.022241 \cdot Sales - 2.6526 \cdot CDD^3 + 0.0015918 \cdot HDD^3$
$R^2_{ajt} = 0.94716$
Resultados obtidos com a MVtool
$Y_{previsto} = 2109.2 + 174.15 \cdot CDD + 0.022241 \cdot Sales - 2.6526 \cdot CDD^3 + 0.0015918 \cdot HDD^3$
$R^2_{ajt} = 0.94716$

Legenda: CDD – Graus-dia de arrefecimento, Sales – Vendas de produtos/serviços, HDD – Graus-dia de aquecimentos

Na tabela 4.2 é possível ver que os resultados do polinómio e do coeficiente de determinação são exatamente iguais, sendo que os dados estão a ser apresentado com cinco algarismos significativos com o objetivo de demonstrar que os resultados são exatamente iguais e não apenas aproximados. Isto prova que a ferramenta criada no decorrer da dissertação está a obter resultados corroborados por uma ESE internacional, o que valida a ferramenta criada independentemente do processo que está por detrás dos resultados obtidos.

Infelizmente não foi possível obter o  $CV[RMSE]$  pelo que não se pode validar o resultado desse parâmetro estatístico. Porém, sendo que esse parâmetro é calculado através dos residuais, tal como o coeficiente de determinação, pode-se assumir que este valor seja válido desde que o método matemático inserido no programa esteja correto. De notar que o método do cálculo destes parâmetros é corroborado por Ross, 2009.

O mesmo ocorre para os *Change Points* calculados. Apesar do método de cálculo ser corroborado por Taylor, 2000, não existem dados para fazer a validação.

Outro parâmetro que não foi possível obter, pois este é um método proposto por esta dissertação, foi a linha que delimita um valor de previsão máximo e mínimo para efeito de identificação de possíveis ajustes à *baseline*. Esta linha delimitadora não é corroborada por nenhum método matemático nem por dados da ESE por isso pode-se dizer que esta linha pode não ser válida. Isto porque o intervalo de confiança é calculado para os valores pré-MCE's, mas a sugestão da dissertação é pegar na diferença entre os limites e o valor esperado e aplicar essa diferença na previsão de consumo pós-MCE's. Isto parece ser algo aceitável, pois aquando do cálculo dos valores do polinómio para estes limites é calculado um desvio e não o valor final. O que pode acontecer é este desvio não corresponder ao mesmo intervalo de confiança (95%) para o qual foi calculado inicialmente. A figura 4.2 apresenta um exemplo do aspeto das linhas delimitadoras.




Figura 4.2 – Exemplo da aplicação da linha delimitadora num gráfico de consumo.

Então, a única maneira de validar estes métodos de identificação de ajustes é testar para um edifício no qual já tenham sido aplicadas as MCE's e que também já tenham sido feitos ajustes à *baseline*, ou seja, isto vai corresponder obrigatoriamente a um edifício onde já tenha sido feito um CDE. Para validar os *Change Points* bastaria comparar os CP obtidos com as datas dos ajustes previamente conhecidos.

A metodologia de validação da linha delimitadora consistiria em pegar nestes dados e verificar os pontos em que o consumo energético ultrapassa uma linha delimitadora, verificar em quais dessas vezes é que foi realizado um ajuste à *baseline* e ainda verificar se houve ajustes à *baseline* em momentos em que o consumo não ultrapassou os limites. Os cenários mais prováveis de ocorrer ao aplicar a metodologia anterior são os seguintes:

1. Nunca foi verificado um consumo que ultrapassasse os limites, mas sabe-se que houve um ajuste na *baseline*.
2. Foram identificados vários pontos esporádicos em que o consumo ultrapassa os limites, mas esses pontos correspondem a menos de 5% dos dados introduzidos. Porém, sabe-se que houve um ajuste na *baseline* numa altura em que o consumo não ultrapassou os limites.
3. Foram identificados vários pontos esporádicos em que o consumo ultrapassa os limites, mas esses pontos correspondem a menos de 5% dos dados introduzidos. Além disso, foi verificada uma situação em que o consumo ultrapassou o limite durante vários dias de seguida e isso levou a um ajuste da *baseline*.
4. Foram identificados vários pontos esporádicos em que o consumo ultrapassa os limites, mas esses pontos correspondem a mais de 5% dos dados introduzidos. Além disso, foi verificada uma situação em que o consumo ultrapassou o limite durante vários dias de seguida e isso levou a um ajuste da *baseline*.
5. O consumo energético está fora dos limites durante períodos alargados (mais de dois/três dias) mais do que uma vez ao longo do ano, mas sabe-se que apenas houve um ajuste na *baseline*.

O cenário 1 não valida este método, mas também não indica que o método esteja errado. Um intervalo de confiança mais largo (por exemplo 90%) pode ser uma solução para superar o cenário 1. O mesmo pode ser dito para o cenário 2. Quanto mais se alarga este intervalo de confiança mais estreita a banda de valores será.

O cenário 3 é um cenário de validação. Os pontos esporádicos são normais, pois existe algum erro no intervalo e os limites definidos conseguem identificar com sucesso uma situação em que foi necessário fazer um ajuste à *baseline*.

O cenário 4 é um cenário que também permite a validação. Mesmo que os casos esporádicos sejam mais de 5%, o intervalo de confiança de 95% é um intervalo médio e por isso existem sempre situações abaixo e acima da média. Se houver uma grande percentagem de dados fora dos limites, então é sempre possível experimentar um intervalo de confiança mais curto (por exemplo 98%) que irá alargar os limites e assim, possivelmente, reduzir o número de pontos fora destes limites.

Ao verificar o cenário 5 terá também de se definir um intervalo de confiança mais curto de forma a alargar os limites e fazer com que mais pontos fiquem dentro dos limites.

Se as soluções propostas nunca levarem a um cenário de validação então este método deverá ser abandonado. Também é importante referir que este método deverá ser testado para vários edifícios para ser considerado válido. O edifício piloto da Câmara Municipal de Mafra será ideal para fazer estes testes num momento mais avançado do projeto MOEEBIUS, pois será um edifício muito monitorizado o que irá facilitar a identificação dos ajustes à *baseline*. De momento, ainda não foram aplicadas as MCE's por isso é impossível fazer esta validação com este edifício e também não é possível a validação com qualquer outro edifício visto que não existem dados disponíveis com a aplicação de MCE's durante o período de registo dos dados nem com os detalhes pretendidos.

Quanto às poupanças obtidas, estas utilizam um método matemático descrito pelos protocolos de M&V pelo que não é necessária a validação no âmbito deste trabalho. Posto isto, a poupança é obtida através do polinómio pelo que a existência de um bom coeficiente de determinação pode ser suficiente para admitir que o valor de poupança real será próximo do valor fornecido pela ferramenta.

#### 4.2.6 – Análise de sensibilidade

Apesar dos resultados obtidos com a ferramenta terem sido validados, existe sempre um fator que depende do utilizador e que pode afetar os resultados, que são os dados de *input* utilizados. Muitas vezes serão utilizados dados de estações meteorológicas que não se situam nos exatos locais dos edifícios em estudo, o que pode causar erros uma vez que as condições meteorológicas podem não ser exatamente as mesmas. Para compreender se esta questão afeta ligeiramente ou significativamente os resultados efetuou-se uma análise de sensibilidade.

Para efetuar esta análise utilizou-se a temperatura exterior de Lisboa para um edifício em Mafra, mantendo todas as outras variáveis. Verificou-se que a média da temperatura exterior em Mafra, no ano *M*, foi de 15.7°C com um desvio padrão de 5.7°C. Em Lisboa, a média para o mesmo período foi de 16.9°C com um desvio padrão de 5.8°C. Apesar do desvio padrão ser semelhante em ambos os locais, verifica-se que Lisboa é, em média, mais quente.

Após a aplicação do modelo criado obteve-se um coeficiente de determinação de 73.4% e um coeficiente de variação de 29.0%. Com a temperatura exterior correta o coeficiente de determinação é de 73.5% e o coeficiente de variação é de 28.9%.

Os coeficientes das duas situações demonstram que não existe praticamente diferença no erro dos dois resultados. Embora os polinómios obtidos sejam diferentes, o erro é semelhante, o que indica ao utilizador da ferramenta que é indiferente utilizar a temperatura de Lisboa ou a temperatura de Mafra para um edifício em Mafra.

O que ocorre é que embora as temperaturas sejam diferentes nos dois locais têm padrões de variação semelhantes e daí o programa não detetar grande diferença. O edifício em causa também é um edifício propício à redução deste erro uma vez que o equipamento de aquecimento, ventilação e ar-condicionado (AVAC) não tem automatização. Em edifícios com grande automatização é possível prever com mais detalhe os horários de funcionamento do AVAC (não é perfeito uma vez que os ganhos internos não são conhecidos), neste caso os utilizadores do edifício é que controlam o AVAC conforme a sua vontade, o que faz com que a temperatura exterior não seja um indicador da utilização do AVAC tão correto como no caso anterior.

#### 4.2.7 – Ferramenta baseada em redes neuronais

Apesar da ferramenta criada de raiz ser baseada numa regressão multilinear, foi testada uma *toolbox* do *Matlab* que permite fazer uma rede neuronal em poucos passos. O objetivo desta rede neuronal é comparar os resultados deste método mais complexo com os resultados da regressão.

Para criar a rede neuronal basta inserir os dados de consumo energético e as variáveis independentes. Posteriormente o *Matlab* oferece uma interface onde se efetuam todos os seguintes passos da rede neuronal. Nesta interface vamos ter de personalizar três parâmetros que são: divisão de dados para teste, validação e aprendizagem, o método de rede a aplicar e o número de neurónios que a rede deverá ter.

Quanto à divisão de dados, os valores *default* apontam para uma divisão 70/15/15, que corresponde a 70% dos dados para teste, 15% dos dados para validação e os outros 15% dos dados para aprendizagem. Este é usualmente o rácio utilizado para qualquer rede neuronal.

O número de neurónios da rede é um dos parâmetros que permite otimizar os resultados obtidos, no entanto quantos mais neurónios são utilizados, mais lenta será a rede neuronal. Foi então sugerida a recomendação de Ascione et al., 2017, que afirma que o número de neurónios a utilizar numa rede

neuronal para previsão de consumos de energia deve ser descoberto através do método de tentativa-erro, mas para previsão de consumos energéticos dez neurónios garante um bom compromisso entre precisão e a habilidade de generalização da rede neuronal.

Por fim, o *Matlab* sugere três métodos diferentes para a execução da rede e uma descrição dos três métodos. Estes são: Método *Scaled Conjugate Gradient* (método que consome menos memória), Método de Levenberg-Marquardt (este método consome mais memória que o *Scaled Conjugate Gradient* mas tipicamente é mais rápido) e método de regularização Bayesiana (método que oferece melhores resultados, especialmente em dados com muito ruído). Visto que os dados de consumo de energia são dados que acabam por ter algum ruído optou-se pelo método de regularização Bayesiana.

#### 4.2.8 – Aplicação - Caso de estudo Câmara Municipal de Mafra

O principal caso de estudo desta dissertação é o edifício piloto do projeto MOEEBIUS (ver no capítulo 2), ou seja, o edifício da Câmara Municipal de Mafra. Este edifício é caracterizado por uma elevada área de vãos envidraçados e conta com 952 trabalhadores.

Os consumos deste edifício foram obtidos através da plataforma de telecontagem da EDP Distribuição, para um período de três anos. As variáveis utilizadas foram apenas as variáveis meteorológicas porque foram as únicas que se conseguiam obter para um grande período de tempo no passado. Para obter novas variáveis estas teriam de ter sido medidas mas isso não era compatível com o período da dissertação visto que as medições teriam de ser efetuadas durante um ano no mínimo.

Os dados meteorológicos foram obtidos com o auxílio do IPMA (Instituto Português do Mar e da Atmosfera). Neste caso foram utilizados dados meteorológicos registados na localidade de Dois Portos, que fica a cerca de 15 quilómetros de Mafra mas que tem uma altitude semelhante. O ideal era os dados serem registados no próprio edifício, mas estes foram os dados que o IPMA conseguiu disponibilizar e que teriam um clima semelhante ao clima de Mafra. Sabe-se que a utilização destes dados adiciona algum erro à regressão realizada, pois as condições meteorológicas não serão exatamente iguais nos dois locais mas tal como foi demonstrado na análise de sensibilidade o erro introduzido será muito pequeno.

Aquando da realização de um projeto ESE as variáveis utilizadas devem ser medidas o mais perto possível do edifício alvo. Contudo, devido ao elevado tempo de espera a opção recai muitas vezes pela utilização de dados de estações meteorológicas nas proximidades.

#### 4.2.9 – Outros casos de aplicação

Além do edifício da Câmara Municipal de Mafra, a ferramenta foi utilizada para criar a *baseline* de outros 4 edifícios:

- Duas escolas, uma localizada em Mafra e outra em Loures. Estes dois edifícios caracterizam-se por uma fraca climatização (apenas existe climatização em pequenas partes dos edifícios) e desse modo espera-se que a ferramenta tenha dificuldades em caracterizar a *baseline*.
- Dois edifícios de escritórios localizados em Lisboa. Ambos com climatização em todo o edifício, pelo que são esperados resultados ao nível dos resultados obtidos para a Câmara Municipal de Mafra.

## Capítulo 5 – Resultados e discussão

### 5.1 - Edifício da Câmara Municipal de Mafra

De modo a otimizar os resultados obtidos para o edifício da Câmara Municipal de Mafra foi criado um primeiro modelo, no qual se usou os dados de modo grosseiro, e posteriormente foi-se otimizando esse modelo ao efetuar algumas melhorias nos dados introduzidos. O modelo considerado ótimo, foi depois utilizado para todos os outros edifícios.

A *baseline* para este edifício foi criada com dados do ano *M*. Antes de apresentar os resultados do polinómio é interessante apresentar uma análise do consumo através de um gráfico matriz, que irá permitir visualizar as horas e dias da semana de maior consumo. A figura 5.1 foi construída para períodos de duas semanas seguidas, uma durante o Inverno e outra durante o Verão. O facto de não serem realizadas para todo o período de Primavera/Verão e todo o período de Outono/Inverno ajuda a reduzir o ruído introduzido pelos feriados ou dias de consumo excecional e ainda a impedir o efeito da variação do consumo ao longo dos meses que poderia dificultar a visualização.



Figura 5.1 – Gráfico matriz de consumos energéticos médios de uma semana representativa da estação de Inverno, para cada hora do dia e para cada dia da semana. Edifício da Câmara Municipal de Mafra

Na figura 5.1 é possível verificar que o consumo energético do edifício aumenta bastante a partir das 5h, hora em que o edifício começa a ter ocupação devido às necessidades de limpeza diárias. Às 9h nota-se outra subida que irá corresponder às horas a que os trabalhadores começam a chegar e, consequentemente, a ligar os equipamentos necessários para o seu trabalho. A partir das 18h o consumo reduz progressivamente até atingir o consumo base, já que é a partir dessa hora que os trabalhadores começam a sair do edifício.

Uma curiosidade possível de observar é que o consumo base do edifício ocorre apenas aos fins-de-semana durante o dia. A razão para isto é que o edifício tem sempre seguranças a trabalhar e estes precisam de iluminação artificial durante a noite, mesmo nos fins-de-semana. Estes são os únicos trabalhadores no edifício nos fins-de-semana e não necessitam de iluminação artificial para desempenhar as suas tarefas durante o dia.

Ao criar o mesmo tipo de gráfico para o período de Verão vê-se que o padrão de consumo parece estar uma hora adiantado do padrão que ocorre no Inverno mas sendo que ambos os gráficos se encontram no Tempo Universal Coordenado (UTC), então sabe-se que durante o Verão é utilizado um horário



diferente no qual se adianta uma hora para obter poupanças de energia ao aproveitar mais a luz do dia. Isto faz com que as 4h do Verão sejam iguais às 5h no Inverno e por isso percebe-se que o padrão de consumo Verão/Inverno é muito semelhante.

Esta análise vai permitir criar uma variável de ocupação qualitativa, ou seja, uma variável de dois valores, ocupado e não ocupado. Mais à frente será visível o efeito desta variável nos resultados da regressão.

### 5.1.1 – Cenário base

Começando então por fazer a regressão mais básica, utiliza-se os dados de consumo energético do ano  $M$  e nos dados das variáveis meteorológicas do IPMA, após a qual se verificam os resultados. Neste primeiro ensaio vai-se utilizar também os consumos e variáveis meteorológicas do ano  $M+1$  para calcular as poupanças. O facto de ser um ano anterior não terá nenhum impacto nos cálculos exceto que o valor de poupanças que a ferramenta calcular vai ser, na realidade, um valor de percentagem de aumento de consumo. Na teoria a ferramenta deveria dizer que não existiram poupanças no ano  $M+1$ , mas devido aos fatores de variabilidade, que não estão incluídos na *baseline*, é normal que a ferramenta produza algum valor de poupanças ou aumento do consumo. A tabela 5.1 apresenta os resultados obtidos aplicando as variáveis meteorologias diretamente na MVtool.

Tabela 5.1 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, sem tratamento de dados

Resultados para o edifício de Mafra – Sem tratamento de dados
$Y_{previsto} = 46.95 - 0.7226 \cdot TE - 0.08068 \cdot HR + 0.2107 \cdot IMV + 0.007815 \cdot GR$
$R^2_{ajt} = 0.123$
$CV[RSME] = 0.527$

Legenda:  $TE$  – Temperatura exterior,  $HR$  – Humidade Relativa,  $IMV$  – Intensidade Média do Vento,  $GR$  – Radiação Global

Apesar dos valores do polinómio não fornecerem nenhuma indicação acerca destes resultados, vê-se que o coeficiente de determinação e o coeficiente de variação apresentam valores bastante afastados dos seus respetivos limites. Isto demonstra que o resultado desta regressão é bastante fraco e que o modelo gerado apenas consegue ser preciso pouco mais de 10% das vezes, como se observa na figura 5.2.

Winter - January




Figura 5.2 – Representação de uma semana de Janeiro, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.1.

No ano  $M+1$ , o consumo de energia fica 8.7% abaixo do esperado, o que é uma diferença significativa sendo que as condições de operação deverão ser as mesmas face ao ano  $M$ , de definição da *baseline*.

### 5.1.2 – Introdução de novas variáveis

O primeiro tratamento de dados que deve ser efetuado é a transformação da temperatura exterior em graus-hora. Para isso devem ser conhecidos os *setpoints* de temperatura interior. Casos estes sejam fixos durante as diferentes estações do ano, o utilizador deve calculá-los e inseri-los como uma nova variável. Caso os *setpoints* sejam constantemente alterados pelos utilizadores do edifício então deve introduzir a temperatura exterior e indicar qual a respetiva coluna. A ferramenta fará um cálculo automático dos *setpoints* que mais se adequam ao consumo. A tabela 5.2 apresenta os resultados após este primeiro tratamento de dados.

Tabela 5.2 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, após a substituição da temperatura pelos graus-hora de aquecimento e arrefecimento.

Resultados para o edifício de Mafra – Graus-hora	
$Y_{previsto} = 23.87 + 0.7379 \cdot CDH + 0.9032 \cdot HDH - 0.04148 \cdot HR + 0.2107 \cdot IMV + 0.007815 \cdot GR$	
$R^2_{ajt} = 0.131$	
$CV[RSME] = 0.524$	

Legenda: CDH – Graus-hora de arrefecimento

O segundo tratamento de dados permitiu obter uma ligeira melhoria dos indicadores de erro. No entanto, esta melhoria não é muito significativa e os resultados continuam a não ser aceitáveis para a utilização deste polinómio como *baseline* deste edifício.

Outro nível de tratamento de dados que se pode utilizar é a introdução de dados exponenciais, utilização do logaritmo ou outro fator de modificação que possa fazer com que o modelo gerado se adapte mais facilmente aos dados fornecidos. A potenciação ao cubo é a operação mais útil sendo que o aumento do valor dos dados irá permitir ao modelo variar mais rapidamente, permitindo assim a captação de

variações rápidas no consumo. Além disso, a potenciação ao cubo tem a vantagem de não tornar os valores absolutos pelo que pode ser utilizada em dados que tenham valores positivos e negativos. Na tabela 5.3 observa-se os resultados obtidos com a introdução de todas as variáveis potenciadas ao cubo.

Por defeito, o programa irá testar os graus-hora ao cubo, caso seja introduzida a temperatura exterior e esta seja posteriormente convertida a graus-hora pela ferramenta. Caso contrário, será o utilizador quem deverá introduzir as modificações de valor adequadas e que tenham potencial para melhorar o modelo gerado.

Tabela 5.3 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, após a introdução de todos os resultados potenciados ao cubo.

Resultados para o edifício de Mafra – Exponenciais
$Y_{previsto} = 17.61 + 1.515 \cdot CDH + 0.9738 \cdot HDH + 0.2858 \cdot IMV + 0.01679 \cdot GR + 3.42 \cdot 10^{-6} \cdot HR^3 - 1.05 \cdot 10^{-9} \cdot GR^3$
$R^2_{ajt} = 0.175$
$CV[RSME] = 0.511$

Legenda: HDH – Graus-hora de aquecimento

Ao comparar a tabela 5.2 e a tabela 5.3 imediatamente verifica-se uma melhoria no modelo que, contudo, continua aquém do esperado.

O terceiro nível de análise foi a introdução da variável binária de ocupação (resultados na tabela 5.4), também referida anteriormente. Para criar esta variável pode-se analisar a figura 5.1 e estabelecer as horas em que o edifício não é ocupado. Adicionalmente, devem ser identificados todos os feriados e tratar estes como fins-de-semana ou, caso se suspeite de um comportamento diferente nos feriados, estes podem ser analisados individualmente.

Tabela 5.4 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, após a introdução de uma variável binária de ocupação.

Resultados para o edifício de Mafra – Ocupação
$Y_{previsto} = 16.50 + 5.103 \cdot 10^{-3} \cdot CDH^3 - 7.433 \cdot 10^{-4} \cdot HDH^3 + 0.9592 \cdot HDR + 0.2966 \cdot IMV + 8.030 \cdot 10^{-4} \cdot GR - 5.37 \cdot 10^{-6} \cdot HR^3 - 7.47 \cdot 10^{-11} \cdot GR^3 + 34.16 \cdot Ocup$
$R^2_{ajt} = 0.735$
$CV[RSME] = 0.289$

Legenda: Ocup – Ocupação binária do edifício

Summer - August




Figura 5.3 - Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.4.

A adição da ocupação ao modelo fez com que este melhorasse significativamente. É possível observar na figura 5.3 que a indicação sobre o estado de ocupação do edifício (ocupado ou não ocupado) fez com que o modelo fosse capaz de prever os consumos muito reduzidos dos fins-de-semana e feriados. Além disso também se observa que o modelo se adaptou melhor aos picos de consumo, apesar destes continuarem a corresponder a uma grande falha na previsão.

Apesar da grande melhoria do modelo que se verificou, continua a existir uma diferença de 8% entre o consumo previsto e o consumo real, no ano  $M+1$ . O facto do valor se manter na mesma ordem apesar da melhoria significativa do modelo leva a pensar que este valor é realmente representativo da realidade, o que é surpreendente visto que o valor de poupanças esperado seria na ordem dos 0% (uma vez que as condições de operação do edifício são iguais entre  $M$  e  $M+1$ ), no entanto este parece não ser o caso.

A inserção de uma variável de ocupação não binária seria um excelente passo na tentativa de previsão dos picos de consumo. O que acontece é que o edifício é ocupado desde as 5h, mas com um consumo de energia muito menos intensivo do que aquele que se verifica umas horas mais tarde. A variável binária faz com que o consumo suba imenso a partir dessa hora e depois mantém-se mais ou menos constante, uma vez que apenas as outras variáveis estão a influenciar o consumo e estas não têm o mesmo nível de influência que a ocupação.

Por fim, existe um passo que tende a melhorar bastante este tipo de modelos que é a adição de uma variável com o consumo da hora anterior. Ao adicionar esta variável, os resultados são os que se apresentam na tabela 5.5.

Tabela 5.5 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, após a introdução do consumo da hora anterior

Resultados para o edifício de Mafra – Consumo da hora anterior	
$Y_{previsto} = 7.58 + 1.216 \cdot 10^{-3} \cdot CDH^3 + 7.900 \cdot 10^{-4} \cdot HDH^3 - 0.2050 \cdot CDH - 0.1149 \cdot IMV$ $- 8.462 \cdot 10^{-4} \cdot GR + 1.22 \cdot 10^{-6} \cdot HR^3 + 1.09 \cdot 10^{-10} \cdot GR^3 + 10.55 \cdot Ocup$ $+ 0.5973 \cdot CHA + 2.19 \cdot 10^{-5} \cdot CHA^3$	
$R_{ajt}^2 = 0.916$	
$CV[RSME] = 0.163$	

Legenda: CHA – Consumo da hora anterior

Tal como se observa (tabela 5.5 e figura 5.4), a adição desta variável permite obter um modelo já extremamente bom, do ponto de vista dos indicadores de erro. No entanto existe um problema que inviabiliza o uso desta variável. O objetivo desta ferramenta é criar *baselines* de consumo para edifícios que irão sofrer alterações e cujo consumo deverá ser menor na segunda fase de utilização da ferramenta, permitindo assim calcular as verdadeiras poupanças obtidas com as alterações, sem a influência de variáveis como as condições meteorológicas. Com a adição do consumo da hora anterior no *dataset* de treino, a ferramenta irá descobrir uma relação entre o consumo da hora anterior e a hora seguinte, depois aquando da realização do cálculo das poupanças obtém-se um valor de consumo na hora anterior mais baixo do que era suposto o que irá fazer com que haja uma subestimação do valor de poupanças obtidas.




Figura 5.4 Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.5.

A figura 5.5 apresenta um gráfico que demonstra a razão da inviabilidade de introdução da variável do consumo da hora anterior.




Figura 5.5 – Exemplificação de previsões de consumo com e sem variáveis dependentes em situações de aplicação de medidas de conservação de energia.

Apesar do consumo previsto sem hora anterior parecer uma previsão muito afastada da realidade, a verdade é que neste exemplo foi introduzida uma poupança de 30% e através da previsão obtém-se uma poupança aproximada de 30%. Apesar deste ter sido um dia aleatório onde existiu uma grande precisão na previsão do consumo a nível diário nem sempre a previsão será tão precisa, mas a partir deste gráfico vê-se que a previsão com hora anterior é muito fraca pois ao aproximar-se dos valores reais está a afastar-se do consumo pré-MCE e, consequentemente, a subestimar as poupanças obtidas, que neste caso nem chegaram a 10%, lembrando que o consumo foi reduzido em 30%.

Apesar de a ferramenta eliminar automaticamente variáveis indesejadas esta variável não será eliminada pela ferramenta, caso seja inserida, pois com a melhoria do erro, a ferramenta irá mantê-la.

### 5.1.3 – Divisão da base de dados

Separar os dados em várias partes consoante as suas características pode ser uma técnica de melhoria do modelo. A mais óbvia seria a separação de dias ocupados e dias não ocupados (resultados nas tabelas 5.6 e 5.7), eliminando assim a variável de ocupação mas produzindo dois polinómios, um para cada um destes períodos.

Tabela 5.6 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra para dias com ocupação.

Resultados para o edifício de Mafra – Separado por ocupação – Dias ocupados	
$Y_{previsto} = 19.69 + 9.112 \cdot 10^{-3} \cdot CDH^3 - 1.193 \cdot 10^{-3} \cdot HDH^3 + 1.413 \cdot HDH - 0.08669 \cdot HR + 6.237 \cdot 10^{-3} \cdot GR + 9.014 \cdot 10^{-3} \cdot IMV^3$	
$R^2_{ajt} = 0.671$	
$CV[RSME] = 0.268$	

Tabela 5.7 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra para dias sem ocupação.

Resultados para o edifício de Mafra – Separado por ocupação – Dias não ocupados	
$R^2_{ajt} = 0.113$	
$CV[RSME] = 0.252$	

As tabelas 5.6 e 5.7 demonstram que a separação dos dados por ocupação não melhorou o modelo logo este não deve ser um passo a seguir neste caso, mas pode ser positivo para outro conjunto de dados.

Existe outro resultado obtido pela ferramenta que são os *Change Points* (CP). Os CP permitem identificar mudanças no padrão de consumo e por isso pode ser uma maneira de melhorar os resultados.

Se forem conhecidas todas as MCE's aplicadas, é possível utilizar os CP para fazer ajustes pontuais na *baseline*, mas também é possível utilizar os CP no período da *baseline* para tentar melhorá-la logo à partida. A ferramenta calcula os CP de primeiro e segundo nível, que correspondem aos três CP mais relevantes (se algum deles não for significativo não aparece no *output*) e assim é possível dividir a série de dados em quatro períodos diferentes e calcular quatro polinómios diferentes para cada período.

A separação em quatro períodos é semelhante a uma separação trimestral por isso serão apresentados os resultados de ambas as separações (tabelas 5.8 e 5.9) para visualizar o efeito dos CP.

Tabela 5.8 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, admitindo uma divisão do ano de baselining em cada Change Point encontrado.

1º Período CP	2º Período CP	3º Período CP	4º Período CP
$R^2_{ajt} = 0.882$	$R^2_{ajt} = 0.788$	$R^2_{ajt} = 0.733$	$R^2_{ajt} = 0.728$
$CV[RSME] = 0.200$	$CV[RSME] = 0.263$	$CV[RSME] = 0.243$	$CV[RSME] = 0.285$

Tabela 5.9 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, admitindo uma divisão do ano de baselining por trimestres.

1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
$R^2_{ajt} = 0.850$	$R^2_{ajt} = 0.718$	$R^2_{ajt} = 0.721$	$R^2_{ajt} = 0.775$
$CV[RSME] = 0.228$	$CV[RSME] = 0.266$	$CV[RSME] = 0.279$	$CV[RSME] = 0.268$

Após uma análise das tabelas 5.8 e 5.9, e tendo em conta os dias em cada período, descobre-se que a separação por CP tem uma pequena vantagem. A principal observação aqui é a melhoria do modelo face ao modelo com um único polinómio. A recomendação para o utilizador é então que separe os dados da forma que lhe seja mais conveniente (apesar da separação por CP ser mais vantajosa na teoria).

Também se verificou que a diferença entre o consumo previsto e o consumo real, no ano  $M+1$ , é aproximadamente de 8% em ambos os casos. Mais uma vez, a melhoria do modelo continua a corroborar uma diferença de aproximadamente 8% entre consumo real e consumo previsto para o ano  $M+1$ .

Também é possível ainda separar os dados em períodos mais pequenos, no entanto, não é aconselhável separar em períodos menores que um mês. Na tabela 5.10 apresenta-se os resultados obtidos com a MVtool ao separar o ano de  $M$  em períodos mensais e realizar a regressão a cada mês individualmente:

Tabela 5.10 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, admitindo uma divisão do ano de baselining por mês.

Janeiro	Fevereiro	Março	Abril
$R^2_{ajt} = 0.883$	$R^2_{ajt} = 0.886$	$R^2_{ajt} = 0.802$	$R^2_{ajt} = 0.787$
$CV[RSME] = 0.200$	$CV[RSME] = 0.200$	$CV[RSME] = 0.259$	$CV[RSME] = 0.254$
Maio	Junho	Julho	Agosto
$R^2_{ajt} = 0.683$	$R^2_{ajt} = 0.718$	$R^2_{ajt} = 0.778$	$R^2_{ajt} = 0.752$
$CV[RSME] = 0.261$	$CV[RSME] = 0.266$	$CV[RSME] = 0.216$	$CV[RSME] = 0.265$



Setembro	Outubro	Novembro	Dezembro
$R^2_{ajt} = 0.761$	$R^2_{ajt} = 0.807$	$R^2_{ajt} = 0.812$	$R^2_{ajt} = 0.816$
$CV[RSME] = 0.252$	$CV[RSME] = 0.203$	$CV[RSME] = 0.240$	$CV[RSME] = 0.262$

A redução do tamanho dos períodos de treino, e correspondentes períodos de teste, tende a melhorar o modelo de forma global, como tem vindo a ser analisado. Tendo em conta a sequência de resultados obtida deixa-se em aberto a metodologia a aplicar pelo utilizador. Se atingir os valores limite dos indicadores de erro indicados pelos protocolos for de extrema importância então pode reduzir os períodos, se a rapidez de execução é o mais importante então pode-se analisar o ano completo.

Winter - January




Figura 5.6 – Exemplificação de previsões de consumo com e sem variáveis dependentes em situações de aplicação de medidas de conservação de energia.

#### 5.1.4 – Técnicas adicionais

Se os resultados ainda não forem os pretendidos, pode-se continuar a fazer algumas operações na tentativa de os melhorar. A redução da periodicidade dos dados é normalmente algo que faz melhorar os indicadores de erro, mas pode não ser muito aconselhado pois o modelo perde escala e os resultados melhores podem refletir-se num pior modelo pois o que aconteceu ao reduzir a periodicidade foi diminuir as variações de consumo, e assim a *baseline* pode prever o consumo futuro com um erro maior. É exatamente isto que se observa na tabela 5.11.

Tabela 5.11 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, utilizando uma periodicidade diária de dados.

Resultados para o edifício de Mafra – Periodicidade diária
$Y_{previsto} = 31.67 - 23.83 \cdot CDH^3 + 3.150 \cdot 10^{-3} \cdot HDH^3 + 44.02 \cdot CDH$
$R^2_{ajt} = 0.103$
$CV[RSME] = 0.343$



Apesar de teoricamente esta operação poder ajudar a melhorar o modelo devido à redução de grandes oscilações, neste caso específico esta operação piorou significativamente o modelo. Provavelmente esta operação estará a ser gravemente afetada pelos dados em falta nas séries de dados, o que altera substancialmente a média diária de muitos dias e assim impede a criação de um bom modelo. Por outro lado, dados meteorológicos como a temperatura média do dia também podem afetar negativamente o modelo pois as temperaturas podem ser diferentes entre as horas ocupadas e não ocupadas.

Por fim, existe a opção de aumentar a série de dados como tentativa de obter melhores resultados. Fazendo a análise para os anos de  $M$  e  $M+1$  obtém-se os seguintes resultados:

*Tabela 5.12 – Resultados obtidos com a MVtool para a Câmara Municipal de Mafra, utilizando dois anos para a caracterização da baseline de consumo.*

<b>Resultados para o edifício de Mafra – Dois anos</b>	
$Y_{previsto} = 2.923 + 3.338 \cdot 10^{-3} \cdot CDH^3 - 1.001 \cdot 10^{-3} \cdot HDH^3 + 0.8026 \cdot CDH + 1.337 \cdot HDH$ $+ 0.1437 \cdot HR + 0.5266 \cdot IMV + 1.841 \cdot 10^{-3} \cdot GR - 1.26 \cdot 10^{-5} \cdot HR^3 - 1.44$ $\cdot 10^{-10} \cdot GR^3 + 33.25 \cdot Ocup$	
$R_{ajt}^2 = 0.707$	
$CV[RSME] = 0.320$	

Contrariamente ao esperado, o modelo criado com uma série de dados de dois anos foi pior em termos estatísticos, que o modelo criado com série de dados de apenas um ano.

É, no entanto, difícil saber se este modelo é realmente pior que o anterior. Se fosse possível analisar um período pós-MCE cujas poupanças eram conhecidas então seria possível verificar qual dos modelos estaria mais perto desse valor. Nesta situação, apenas se sabe que a correlação entre as variáveis e o consumo é pior, mas mesmo assim este novo polinómio pode ser um polinómio mais “flexível”, que se adapta melhor ao consumo de anos futuros.

A sugestão aos utilizadores é utilizarem sempre a maior série de dados disponível, desde que o utilizador consiga garantir que as condições de operação no edifício foram semelhantes durante todo o período que vai analisar.

Estes períodos maiores também são passíveis de serem divididos por *Change Points* ou mensalmente para conseguir uma melhor correlação entre as variáveis e o consumo.

## 5.2 - Escolas em Mafra e em Loures

A ferramenta criada foi igualmente aplicada em duas escolas (uma em Mafra e outra em Loures), tendo sido realizado o mesmo tipo de tratamento de dados para o qual se obteve melhores resultados no edifício da Câmara de Mafra. Visto que se observou uma grande dependência da ocupação na construção do modelo então é necessário compreender qual é o novo horário de funcionamento do edifício. Tal foi realizado criando um gráfico matriz como o da figura 5.1.

A tabelas 5.13 e 5.14 demonstram os resultados dos coeficientes obtidos e a figura 5.7 representa o polinómio gerado na Escola de Mafra:

Tabela 5.13 – Resultados da MVtool com tratamento de dados otimizado para a Escola de Mafra.

Resultados para a Escola de Mafra	
$R^2_{ajt} = 0.509$	$CV[RSME] = 0.202$




Figura 5.7 - Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.13.

O coeficiente de determinação obtido demonstra que o modelo criado não consegue prever com precisão o consumo energético. Este facto pode ser observado na figura 5.7, onde se observa que a previsão se encontra bastante afastada do consumo real. Como tal, é impossível utilizar este modelo para caracterizar a *baseline* da escola de Mafra.

A principal razão para isto ocorrer será a fraca relação com as condições meteorológicas. Segundo a discriminação de equipamentos elétricos todo este complexo apenas tem uma unidade *split* e alguns aquecedores elétricos a óleo. Todos os outros equipamentos têm uma utilização apenas dependente da ocupação e do tipo de atividade a decorrer.

O exemplo da Escola de Loures é igual ao da Escola de Mafra, sendo este um edifício onde a climatização é quase inexistente.

Tabela 5.14 - Resultados da MVtool com tratamento de dados otimizado para a Escola de Loures.

Resultados para a Escola de Loures	
$R^2_{ajt} = 0.639$	$CV[RSME] = 0.617$

Com um coeficiente de variação ainda pior que no caso anterior, a Escola de Loures é outro exemplo em que não é possível utilizar a ferramenta para determinar a *baseline* de consumo. Para fazer um CDE neste tipo de edifícios será mais fácil basear as poupanças nos equipamentos substituídos, por exemplo, substituindo um projetor de 300 W por um de 200 W e sabendo que ele é usado 3 horas por dia, nos dias

de semana, é possível dizer que o novo equipamento permitirá poupar cerca de 78 kWh ao fim de um ano. A normalização às condições meteorológicas não será problema devido à fraca relação que existe.

### 5.3 - Edifícios de escritórios em Lisboa

Foram também testados dois edifícios de escritórios localizados em Lisboa: edifício A e edifício B.

A figura 5.8 mostra o gráfico matriz para os meses de Inverno no edifício B. A principal diferença deste padrão para o padrão observado no gráfico matriz do edifício A é que neste segundo edifício o consumo começa a reduzir a partir das 16h, enquanto que no edifício B apenas começa a reduzir a partir das 18h.

O edifício A tem 10 pisos (incluindo os pisos subterrâneos) e utiliza 144 unidades de *split* para a climatização individual.

O edifício B tem o mesmo número de pisos, mas utiliza um parque de 23 unidades VRV (Volume Refrigerante Variável) para a climatização centralizada.

Mais uma vez utilizou-se o gráfico matriz (figura 5.8) para determinar os períodos de ocupação dos edifícios, que tem um padrão semelhante nos dois edifícios.




Figura 5.8 - Gráfico matriz de consumos energéticos médios de uma semana representativa da estação de Inverno para cada hora do dia e para cada dia da semana. Edifício de escritórios A.

Aplicando a ferramenta aos dados do edifício A obtêm-se os seguintes resultados:

Tabela 5.15 - Resultados da MVtool com tratamento de dados otimizado para o edifício de escritórios A.

Resultados para o edifício A
$Y_{previsto} = 167.1 + 6.660 \cdot CDH - 1.263 \cdot HDH + 0.3363 \cdot HR + 6.747 \cdot 10^{-3} \cdot RG + 5.57 \cdot 10^{-6} \cdot HR^3 + 225.9 \cdot Ocup$
$R^2_{ajt} = 0.818$
$CV[RSME] = 0.202$

Imediatamente pode ser feita uma análise comparativa com o edifício da Câmara Municipal de Mafra. Em primeiro lugar vê-se que os graus-hora de aquecimento influenciam negativamente o modelo, ao contrário do que acontece com a Câmara Municipal de Mafra. É provável que isto se deva ao facto de o

edifício não necessitar de aquecimento, e assim, quando a temperatura exterior é baixa não vai ser necessário arrefecer tanto o edifício.

Outro apontamento vai para o desaparecimento da variável da intensidade média do vento, o que indica que esta não tinha uma relação com o consumo suficientemente forte para considerar a variável relevante para a construção do modelo.

Quanto aos coeficientes, pode-se dizer que ambos estão dentro dos limites recomendados pelo IPMVP, o que significa que este modelo é considerado como um modelo sólido para previsão de consumos.

Este modelo foi utilizado para prever o consumo dos últimos quatro meses do ano anterior e obteve-se apenas uma diferença de 3% entre o consumo previsto e o consumo real.

A figura 5.9 representa a previsão de consumo e o consumo real para semana de 13 a 20 de Agosto do ano  $M+1$ . Na medida em que o consumo total obtido através da previsão era 3% menor que o consumo total real seria de esperar que a previsão fosse mais próxima da realidade, no entanto o consumo previsto mais elevado, que se visualiza na figura 5.9, é compensado por outras semanas em que o consumo previsto é inferior ao consumo real. O método de separação dos dados em diferentes meses, que foi apresentado anteriormente, poderia ser uma solução para melhorar estes resultados.




Figura 5.9 - Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.13.

A tabela 5.16 resume os resultados obtidos para o último edifício testado:

Tabela 5.16 - Resultados da MVtool com tratamento de dados otimizado para o edifício de escritórios B.

Resultados para o edifício B
$Y_{previsto} = 46.03 + 4.185 \cdot 10^{-3} \cdot HDH^3 + 2.737 \cdot CDH - 0.6830 \cdot HDH + 0.7739 \cdot IMV - 2.8 \cdot 10^{-3} \cdot RG - 1.39 \cdot 10^{-3} \cdot IMV^3 + 9.17 \cdot 10^{-10} \cdot RG^3 + 53.55 \cdot Ocup$
$R_{ajt}^2 = 0.758$
$CV[RSME] = 0.215$

O edifício B parece ser muito semelhante ao edifício da Câmara Municipal de Mafra, além do uso de todas as variáveis também tem coeficientes muito semelhantes. A discussão de resultados deste edifício acaba então por ser igual à discussão realizada no edifício da Câmara Municipal de Mafra, ou seja, embora o erro seja ligeiramente superior ao limite indicado este pode ser um bom modelo. Existem fatores, como a ausência de variáveis relevantes, que afetam o modelo e aumentam o erro apesar do modelo conseguir ainda efetuar uma boa previsão.

Neste caso não existe outro período para além do período da *baseline* para prever consumos e comparar resultados por isso não é possível provar se o modelo é bom ou não, mas a análise visual da *baseline*, na figura 5.10, demonstra uma boa relação entre o consumo previsto e o consumo real.




Figura 5.10 - Representação de uma semana de Agosto, de dados de consumo previsto e dados de consumo medida para o modelo da tabela 5.13.

## 5.4 - Rede Neuronal – Comparações com a MVtool

As redes neurais são um método empírico de previsão de consumo, tal como a regressão. No entanto, ao contrário da regressão, as redes neurais são um método dinâmico pelo que têm uma capacidade de reconhecer padrões, o que não acontece na regressão.

### 5.4.1 – Edifício da Câmara Municipal de Mafra

Para comparar os resultados de uma rede neuronal com os resultados obtidos com a MVtool foi criada uma rede que utilizou exatamente os mesmos *inputs* que foram inseridos na MVtool na versão de periodicidade horária otimizada, que foi a versão que apresentou a melhor relação qualidade/complexidade, tal como foi descrito no capítulo 4. Na tabela 5.17 apresenta-se a comparação entre os resultados para o edifício da Câmara Municipal de Mafra (CMM):

Tabela 5.17 – Comparação de resultados da MVtool e da rede neuronal para o edifício da Câmara Municipal de Mafra.

Resultados para o edifício de Mafra – Ocupação	
$R^2_{ajt} = 0.735$	$CV[RSME] = 0.289$
Diferença entre consumo real e previsto ( $M+1$ ) = 8.0%	
Resultados com a rede neuronal	
$R^2_{ajt} = 0.961$	$CV[RSME] = 0.226$
Diferença entre consumo real e previsto ( $M+1$ ) = 7.1%	

Observando a tabela 5.17 pode-se afirmar que os resultados obtidos com a rede neuronal são melhores que os resultados obtidos com a MVtool. Isto era o esperado de um modelo dinâmico, uma vez que, a sua capacidade de reconhecer padrões permite obter uma previsão muito mais precisa. A utilização de grandes períodos temporais deve evitar o reconhecimento de padrões errados, o que poderá melhorar os resultados mas irá reduzir a precisão, que foi o mesmo que se verificou com a regressão.

As figuras 5.11 e 5.12 reforçam os resultados observados na tabela 5.17. É visível a que a previsão dada pela rede neuronal encaixa muito melhor no consumo real do que a previsão dada pela regressão.




Figura 5.11 – Comparação de resultados de previsão obtidos com o consumo real para uma semana de Inverno na CMM.




Figura 5.12 – Comparação de resultados de previsão obtidos com o consumo real para uma semana de Verão na CMM.

Este grande potencial das redes neuronais coloca a questão se não seria melhor a ferramenta criada ser baseada numa rede neuronal em vez de ser baseada numa regressão. As redes neuronais são muito complexas e demoram algum tempo a executar, mas se fosse criado um programa “amigo do utilizador” de raiz, focado nos resultados pretendidos para aplicar o modelo de negócio em estudo, então o único ponto negativo da rede neuronal seria o tempo de execução e em todos os outros aspetos seria, teoricamente, superior à regressão multilinear. O principal obstáculo a tornar isto uma realidade é a complexidade da criação de uma rede neuronal de raiz.

#### 5.4.2 – Escola de Mafra e Escola de Loures

Nas escolas, os resultados obtidos com a MVtool não foram bons uma vez que as variáveis utilizadas não conseguiam justificar as variações de consumo. Com a rede neuronal o caso é um pouco diferente, para a escola de Loures (tabela 5.18) o CV[RMSE] continua muito acima dos limites definidos nos protocolos, pelo que é necessária uma atenção especial na utilização desta *baseline*. Na figura 5.13 vê-se que a correspondência entre a previsão com a rede neuronal e o consumo real está tão próxima como no caso anterior da Câmara Municipal de Mafra.

Tabela 5.18 - Comparação de resultados da MVtool e da rede neuronal para a Escola de Loures.

Resultados MVtool – Escola de Loures	
$R^2_{ajt} = 0.639$	$CV[RSME] = 0.617$
Diferença entre consumo real e previsto ( $M+1$ ) = 5.7%	
Resultados com a rede neuronal	
$R^2_{ajt} = 0.920$	$CV[RSME] = 0.406$
Diferença entre consumo real e previsto ( $M+1$ ) = 4.1%	






Figura 5.13 - Comparação de resultados de previsão obtidos com o consumo real para uma semana de Inverno na Escola de Loures.

No caso da escola de Mafra os resultados obtidos (tabela 5.19) estão todos dentro dos limites definidos, pelo que se pode considerar que a caracterização da *baseline* é muito boa. Comparando os resultados com a MVtool verifica-se uma grande diferença. A única justificação para tal será o consumo da escola de Mafra ser de tal maneira padronizado que a rede neuronal conseguiu detetar todas as variações significativas no período de treino, apesar das variáveis introduzidas não traduzirem estas variações com precisão.

Tabela 5.19 - Comparação de resultados da MVtool e da rede neuronal para a Escola de Mafra.

Resultados com a rede neuronal – Escola de Mafra	
$R^2_{ajt} = 0.982$	$CV[RSME] = 0.140$
Diferença entre consumo real e previsto ( $M+1$ ) = 5.4%	
Resultados MVtool	
$R^2_{ajt} = 0.509$	$CV[RSME] = 0.202$
Diferença entre consumo real e previsto ( $M+1$ ) = 14.6%	

### 5.4.3 – Edifícios de escritórios

Em ambos os edifícios de escritórios todos os resultados estão dentro dos limites dos protocolos, o que nem sempre ocorreu com a MVtool. Esta melhoria demonstrou que o erro das *baselines* caracterizadas reduziu em todos os edifícios estudados pelo que se pode concluir que o utilizador deve optar pelo uso de uma rede neuronal caso o seu objetivo principal seja reduzir o erro.

As tabelas 5.20 e 5.21 demonstram os resultados obtidos para o edifício A e para o edifício B respetivamente. A figura 5.14 compara as duas previsões e o consumo real para o edifício A, numa semana representativa da estação de Inverno.



Tabela 5.20 - Comparação de resultados da MVtool e da rede neuronal para o edifício A.

Resultados MVtool – Edifício A	
$R^2_{ajt} = 0.818$	$CV[RSME] = 0.202$
Diferença entre consumo real e previsto (M+1) = 3.3%	
Resultados com a rede neuronal	
$R^2_{ajt} = 0.986$	$CV[RSME] = 0.133$
Diferença entre consumo real e previsto (M+1) = 2.3%	

Tabela 5.21 - Comparação de resultados da MVtool e da rede neuronal para o edifício B.

Resultados MVtool – Edifício B	
$R^2_{ajt} = 0.758$	$CV[RSME] = 0.215$
Resultados com a rede neuronal	
$R^2_{ajt} = 0.980$	$CV[RSME] = 0.154$




Figura 5.14 - Comparação de resultados de previsão obtidos com o consumo real para uma semana de Inverno no edifício A.

Tal como na regressão, observou-se que o edifício A continua a ser o edifício testado para o qual o erro é mais pequeno. Uma justificação para tal é este ser o edifício onde existe o maior consumo energético para climatização, uma vez que o edifício utiliza 144 unidades de *split*, e assim todas as variações que não conseguem ser justificadas pelas variáveis meteorológicas têm menos efeito no modelo gerado já que correspondem a uma menor percentagem do consumo.

---

## Capítulo 6 – Conclusões

Com a análise das várias melhorias efetuadas, ao nível dos dados de *input* para a MVtool, no edifício da Câmara Municipal de Mafra (CMM) é perceptível que os coeficientes e os polinómios alteram significativamente, mas existe algo que se mantém dentro de uma pequena faixa de valores, que são as diferenças entre consumo previsto e consumo real na totalidade do período de análise. A MVtool prevê os consumos para a mesma periodicidade dos dados inseridos, ou seja, neste caso está a efetuar uma previsão de quinze em quinze minutos. A integração de todas as previsões é que permite obter um consumo previsto para a todo o período de análise.

A diferença anual entre o consumo previsto e real, para um período não utilizado na caracterização da *baseline*, apresenta sempre valores que são corroborados pela MVtool e pela rede neuronal, independentemente do tratamento de dados utilizados (exceto os testes com variáveis dependentes, nomeadamente o consumo atrasado no tempo), isto demonstra que a regressão é uma boa solução para criar *baselines* cujo propósito é analisar longos períodos de tempo, mesmo quando o erro é elevado. O erro elevado tem como consequência a pouca precisão, que se observa, na dificuldade de captação do perfil de quinze em quinze minutos.

Daqui pode-se concluir que a regressão multilinear é um método com boa exatidão, mas com fraca precisão. Já a rede neuronal testada aparenta ter uma boa precisão e também uma boa exatidão, já que tem um erro reduzido e corrobora as diferenças anuais de consumo detetadas.

A utilização, ou não, de variáveis dependentes na regressão permitiu concluir que a utilização destas variáveis reduz o erro de forma muito significativa, mas que este tipo de variáveis não pode ser utilizado caso haja alterações no consumo, uma vez que estas variáveis vão mitigar qualquer alteração no consumo que tenha ocorrido, tal como ficou demonstrado.

Outro facto que se observou foi que a previsão dos edifícios é muito dependente da sua ocupação. Como tal, a ocupação deve ser sempre uma variável conhecida para conseguir criar *baselines* fortes. No mínimo deve ser conhecida a variação anual para efetuar os ajustes necessários.

Quanto às redes neuronais, consegue-se concluir que as redes neuronais são um método mais preciso que a regressão utilizada. No futuro seria interessante desenvolver uma ferramenta baseada numa rede neuronal, embora o desenvolvimento de uma rede seja um processo complexo, quer a nível da programação quer a nível das técnicas de *data mining* necessárias para a desenvolver. Também seria interessante comparar os resultados da MVtool com os resultados da rede neuronal para edifícios reabilitados, de forma a conhecer os resultados alvo e verificar qual dos métodos se aproxima mais da realidade.

Por fim, é possível retirar algumas conclusões acerca do modelo de negócio em estudo. Sendo este modelo de negócio baseado em medidas com baixo tempo de recuperação de investimento, então este modelo apenas consegue funcionar se o cálculo das poupanças for preciso. A título de exemplo pode-se pegar na situação da CMM, onde se verificou que existiu uma diferença de 7% entre o consumo previsto e o consumo real, para o ano  $M+1$ , utilizando o ano  $M$  para caracterizar a *baseline*. Não é possível retirar grandes conclusões acerca desta poupança detetada visto que as diferenças nas condições de operação do edifício entre estes períodos não são conhecidas, mas caso fosse realizado um contrato de desempenho energético, e fossem aplicadas medidas de conservação de energia entre estes anos, as poupanças detetadas seriam sobrestimadas. Com isto conclui-se que os ajustes pontuais à *baseline* são essenciais para o funcionamento desde modelo de negócio e como tal a MVtool apenas poderá ser aplicada após a validação dos métodos de identificação de ajustes (*Change Points* e linha delimitadora)

com edifícios que já foram sujeitos a um CDE, de forma a comparar os ajustes sugeridos pela MVtool e os ajustes realizados pela ESE, que fez a gestão do edifício de validação.

## Referências

- [1] IEA (2014), World Energy Outlook 2014, International Energy Agency.
- [2] IEA (2016), World Energy Outlook 2016, International Energy Agency.
- [3] IPCC (2014), Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, R.K. Pachauri and L.A. Meyer (eds.)]. IPCC, Geneva, Switzerland, 151 pp.
- [4] IEA (2016), Energy Efficiency Indicators Highlights (2016 edition), International Energy Agency.
- [5] Modelling Optimization of Energy Efficiency in Buildings for Urban Sustainability (2015), Proposal to Horizon 2020.
- [6] IEA (2016), Energy Efficiency Market Report 2016, International Energy Agency.
- [7] Parlamento Europeu (2010), Directiva 2010/31/UE do Parlamento Europeu e do Conselho de 19 de Maio de 2010 relativa ao Desempenho Energético dos Edifícios, Bruxelas.
- [8] Ministério da Economia e do Emprego, Decreto-Lei n.º 118/2013 de 20 de agosto, Diário da República, 1.ª série, N.º 159, 20 de agosto de 2013.
- [9] U.S. Department of Energy (2011), A guide to Performance Contracting with ESCOs.
- [10] MOEEBIUS Project (2016), New Business Models and Associated Energy Management Strategies, Deliverable to Horizon 2020.
- [11] U.S. Department of Energy (2002), International Performance Measurement and Verification Protocol.
- [12] U.S. Department of Energy (2015), M&V Guidelines: Measurement and Verification for Performance-Based Contracts, version 4.0.
- [13] Investor Confidence Project (2016), Energy Performance Protocol – Project Development Specification. [online] Available at: <http://www.eepperformance.org/project-development-specification.html> [Accessed 30/1/2017].
- [14] MOEEBIUS Project (2016), End-User Business Requirements, Deliverable to Horizon 2020.
- [15] MOEEBIUS Project (2016), MOEEBIUS Energy Performance Assessment Methodology, Deliverable to Horizon 2020.
- [16] Corgnati, S., Bednar, T., Jang, Y., Yoshino, H., Filippi, M., Danov, S., Nord, N., Schweiker, M., Ghiaus, C., Capozzoli, A., Talà, N. and Fabi, V. (2013). Total Energy Use in Buildings - Analysis and Evaluation Methods. Tokyo, Japan: Institute for Building Environment and Energy Conservation, Volume V-1.
- [17] Ascione, F., Bianco, N., De Stasio, C., Mauro, G. and Vanoli, G. (2017). Artificial neural networks to predict energy performance and retrofit scenarios for any member of a building category: A novel approach. *Energy*, 118, pp.999-1017.
- [18] Ben-Israel, A. and Greville, T. (2012). Generalized inverses. New York: Springer.
- [19] DEXMA. (2017). Energy Management Software | DEXCell Energy Manager. [online] Available at: <http://www.dexmatech.com/> [Accessed 18 May 2017].
- [20] EnergyPlus. (2017). EnergyPlus Whole Building Energy Simulation Software. [online] Available at: <https://energyplus.net/> [Accessed 13/9/2017].
- [21] Muralitharan, K., Sakthivel, R. and Vishnuvarthan, R. (2017). Neural network based optimization approach for energy demand prediction in smart grid. *Neurocomputing*.
- [22] Noesis. (2017). Noesis Building Equipment Financing. [online] Available at: <https://www.noesis.com/> [Accessed 22/3/2017].
- [23] Python. (2001). Python Programming Language. [online] Available at: <https://www.python.org/> [Accessed 4/9/2017].

- [24] Ross, S. (2009). Introduction to probability and statistics for engineers and scientists. Amsterdam: Elsevier.
- [25] Taylor, W. (2000). Change-Point Analysis: A Powerful New Tool For Detecting Changes. [online] Available at: <http://www.variation.com/cpa/tech/changepoint.html> [Accessed 17/6/2017].
- [26] Zaiontz, C. (2017). Real Statistics Using Excel. [online] Available at: <http://www.real-statistics.com> [Accessed 1/6/2017].

## Anexo I – Business Model Canvas

<b>7 - Key partners</b> Technical partners (Suppliers of monitoring systems; control systems; meters, ICT);  ESCOs offering energy management services.	<b>5 - Key activities</b> Establishing data connection and collection; Integrated energy and contextual management framework.  <b>6 - Key resources</b> Data acquisition from heterogeneous sensor and metering devices; Software that enables the integrated management of building premises.	<b>1 - Value proposition</b> Energy savings without investment offered by an ESCO; Energy savings fully preserving contextual and operational building parameters.	<b>4 - Customer relationships</b> Contractual (short to medium-term) incentivised by the desire to obtain energy savings fully preserving building occupants preferences.  <b>3 - Channels</b> Personal sales; Exhibitions; Utilities; Public projects; Special events.	<b>2 - Customer segments</b> Building owners that do not have an internal team for energy management (have no one monitoring energy bills);  Buildings that have potential for energy savings; Commercial and public buildings that are willing to increase holistic building performance.
<b>9 - Cost structure</b> Technology and labour cost; Small investment in equipment; maintenance or optimisation (measures with fast paybacks, e.g. < 1 year – low cost or no cost).		<b>8 - Revenue streams</b> Energy savings from the project (for example: 50% for the ESCO and 50% for the costumer) as in typical ESCO models. The main differentiation is the incorporation of contextual and operational building parameters on optimization process.		

Figura A.I.1 - Business Model Canvas para modelo de negócio “Serviços de Gestão de Energia baseado num CDE melhorado” [10].

## Anexo II – Guia de utilização da MVtool

Antes de descrever os passos de utilização são descritos alguns pontos aos quais os utilizadores devem ter atenção:

- A MVtool não carece de instalação pelo que pode ser utilizada em qualquer computador.
- A MVtool corresponde a uma pasta na qual se encontra um ficheiro executável e um ficheiro .xlsx.
- O utilizador deve ter o cuidado de verificar se o ficheiro executável não está a ser barrado pela firewall do sistema.
- O utilizador NUNCA deve modificar o nome de qualquer um dos ficheiros nem tirar os dois ficheiros de dentro da pasta.
- Todos os nomes de variáveis adicionados no ficheiro .xlsx devem ter apenas caracteres pertencentes à tabela ASCII.
- Após o programa ser executado, e caso não ocorra nenhum erro, serão gerados dois ficheiros .jpg que correspondem a dois gráficos que devem representar uma semana de Inverno e uma semana de Verão do consumo previsto e consumo real para o período inserido na folha “Savings” do ficheiro input.xlsx.
- Após o programa ser executado, e caso não ocorra nenhum erro, será gerado um ficheiro chamada polinomial.csv, que contém o polinómio da *baseline* caracterizada na segunda coluna. A terceira e quarta coluna correspondem a dois polinómios que servirão para construir as linhas delimitadoras referidas na dissertação.

Para a utilização correta da MVtool devem ser seguidos os seguintes passos:

1. Abrir o ficheiro input.xlsx (existem duas folhas dentro deste ficheiro, uma chamada “Baseline” e outra chamada “Savings”).
2. Na folha “Baseline” o utilizador deve meter os dados de input com os quais pretende criar a *baseline* de consumo. A primeira linha está reservada para os nomes das variáveis que pretenda utilizar e a primeira coluna está reservada para os dados de consumo energético medido. Todas as outras colunas podem ser utilizadas para adicionar as variáveis sobre as quais a MVtool irá efetuar a regressão. Nenhuma coluna deverá ter caracteres não numérica para além dos nomes das variáveis.
3. (Facultativo) Na folha “Savings” devem adicionadas as mesmas variáveis utilizadas na folha “Baseline” mas para o período de tempo para o qual o utilizador pretende verificar a existência de diferenças no consumo. Mais uma vez, a primeira linha está reservada para os nomes das variáveis. A primeira coluna está reservada para as datas das medições efetuadas e a segunda coluna para os consumos energéticos deste novo período. As variáveis introduzidas nas restantes colunas TÊM de ficar exatamente na mesma ordem que foi utilizada na folha “Baseline”.
4. Após gravar o ficheiro input.xlsx, o utilizador está pronto a correr a MVtool.exe.
5. Após alguns segundos a correr o programa irá aparecer uma pergunta: “Did you use Exterior Temperature as one of your variables?”. Caso o utilizador tenha utilizado a temperatura exterior e pretenda mudar para graus-hora deve dizer que sim. Em caso afirmativo o programa pede o número da coluna onde se encontra a temperatura exterior.
6. Em seguida o programa pergunta ao utilizador se este pretende calcular os *Change Points* no período da *baseline*. Caso o utilizar não o pretenda deve dizer que não pois este processo reduz

---

a velocidade de execução do programa. Tal como foi descrito no corpo da dissertação, os *Change Points* servem para identificar desvios no consumo, que por sua vez podem corresponder a períodos onde seja necessário realizar ajustes à *baseline*.

7. A pergunta seguinte que o programa faz é se o utilizador pretende calcular as poupanças. Esta pergunta mete-se pelo motivo que este ponto não é algo obrigatório de efetuar pois o propósito principal da ferramenta é caracterizar a *baseline*. Se o utilizador apenas pretender caracterizar a *baseline* então pode responder pela negativa à pergunta colocada e se tal acontecer não é necessário colocar quaisquer dados na folha “Savings” do ficheiro input.xlsx.
8. Por fim, se a resposta à pergunta anterior for positiva, o programa irá perguntar se o utilizador pretende calcular os *Change Points* para o período da folha “Savings” do ficheiro input.xlsx.

Estes 8 passos são todos os passos necessários para trabalhar com a MVtool. De seguida encontram-se exemplos da organização do ficheiro input.xlsx e do *output* do MVtool.exe:



	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
1	Energia [kWh]	Temperatura	Humidade Relativa																
2	14	8	60																
3	20	13	83																
4	2	2	9																
5	7	5	29																
6	8	5	32																
7	2	1	6																
8	13	9	60																
9	2	1	7																
10	14	12	66																
11	10	9	50																
12	7	7	33																
13	4	4	16																
14	15	15	74																
15	12	12	59																
16	11	11	57																
17	3	3	17																
18	13	10	69																
19	16	12	79																
20	15	10	62																
21	9	6	33																

Figura A.II.1 – Exemplo da folha “Baseline” do ficheiro input.xlsx

input.xlsx - Excel

Inicio sessão

Ficheiro Base Inserir Esquema de Página Fórmulas Dados Rever Ver Diga-me o que pretende fazer Partilhar

Colar

Calibri 11

Moldar Texto

Personalizado

Formatação Condicional

Formatar como Tabela

Estilos de Célula

Inserir Eliminar Formatar

Soma Automática

Preenchimento

Limpar

Ordenar e Filtrar

Localizar e Selecionar

Edição

Área de Tr...

Tipo de Letra

Alinhamento

Número

A2

01/01/2015 00:00:00

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
1	Date	Energia [kWh]	Temperatura	Humidade Relativa														
2	01/01/2015 00:00	18	2	74														
3	01/01/2015 01:00	7	1	30														
4	01/01/2015 02:00	2	1	9														
5	01/01/2015 03:00	6	1	24														
6	01/01/2015 04:00	1	1	2														
7	01/01/2015 05:00	12	1	47														
8	01/01/2015 06:00	14	0	58														
9	01/01/2015 07:00	16	0	69														
10	01/01/2015 08:00	2	1	7														
11	01/01/2015 09:00	4	1	13														
12	01/01/2015 10:00	3	1	9														
13	01/01/2015 11:00	6	4	19														
14	01/01/2015 12:00	13	11	31														
15	01/01/2015 13:00	11	10	24														
16	01/01/2015 14:00	1	1	1														
17	01/01/2015 15:00	6	6	15														
18	01/01/2015 16:00	12	12	31														
19	01/01/2015 17:00	8	6	22														
20	01/01/2015 18:00	6	3	21														
21	01/01/2015 19:00	21	9	75														

Baseline Savings

Pronto

100%

Figura A.II.2 – Exemplo da folha “Savings” do ficheiro input.xlsx

```
The program is running, please wait...
Make sure you have the polynomial file closed (if it is not the first time you run the program)
Also make sure that all characters in your variables names are present in the ASCII table
...
...
...
Did you use Exterior Temperature as one of your variables?
[Y/N] y
In which column?
[Number] 2
(20, 23)
The correlation between data is not enough to consider the results of the regression statistically significant
('R^2 = ', 0.73530081886303766)
('CV = ', array([ 0.2893997]))
Do you want to calculate change points for the baseline period?
[Y/N] y
(2529, 100)
(1691, 100)
(4433, 100)
Do you want to calculate energy savings?
[Y/N] y
('Estimated Savings = ', 0.08036141742757288)
Do you want to calculate change points for the new period?
[Y/N] y
(1721, 100)
(1081, 100)
(7455, 100)
PRESS ENTER TO EXIT
```

Coefficiente de determinação e coeficiente de variação do RMSE

Posição dos Change Points no ficheiro input.xlsx e o seu grau de confiança (0 a 100)

Diferença entre o consumo dos dois períodos utilizados

Figura A.II.3 – Exemplo de output da MVtool.